

VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA
EKONOMICKÁ FAKULTA

KATEDRA FINANČÍ

Testování kointegrace mezi odvětvovými indexy akciového trhu

Testing of Cointegration among Sectoral Stock Market Indexes

Student: Bc. Jan Šafarčík

Vedoucí diplomové práce: Ing. Martina Novotná, Ph.D.

Ostrava 2015

VŠB - Technická univerzita Ostrava
Ekonomická fakulta
Katedra financí

Zadání diplomové práce

Student: **Bc. Jan Šafarčík**
Studijní program: N6202 Hospodářská politika a správa
Studijní obor: 6202T010 Finance
Téma: **Testování kointegrace mezi odvětvovými indexy akciového trhu**
Testing of Cointegration among Sectoral Stock Market Indexes

Zásady pro vypracování:

1. Úvod
 2. Podstata akciových indexů
 3. Charakteristika analýzy časových řad
 4. Testování kointegrace mezi vybranými akciovými indexy
 5. Závěr
- Seznam použité literatury
Seznam zkratk
Prohlášení o využití výsledků diplomové práce
Seznam příloh
Přílohy

Seznam doporučené odborné literatury:


BODIE, Z., A. KANE and A. MARCUS. *Investments and portfolio management*. 9th ed. Global ed. New York: McGraw-Hill/Irwin, 2011. 1056 s. ISBN 978-007-1289-146.
HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. 214 s. ISBN 978-80-7431-088-1.
MUSÍLEK, Petr. *Trhy cenných papírů*. 2. vyd. Praha: Ekopress, 2011. 520 s. ISBN 978-80-86929-70-5.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Martina Novotná, Ph.D.**

Datum zadání: 21.11.2014
Datum odevzdání: 25.04.2015




Ing. Iveta Ratmanová, Ph.D.
vedoucí katedry


prof. Dr. Ing. Dana Dluhošová
děkanka fakulty

Prohlašuji, že jsem celou práci, včetně všech příloh, vypracoval samostatně.

V Ostravě dne 24. 4. 2015

Bc. Jan Šafář
Bc. Jan Šafář

Poděkování

Tímto bych rád poděkoval Ing. Martině Novotné, PhD. za odborné konzultace, připomínky a cenné rady, které mi poskytla během jednotlivých konzultací.

Obsah

1	Úvod.....	6
2	Podstata akciových indexů	7
2.1	Indexy	7
2.1.1	Obyčejné průměry	8
2.1.2	Vážené aritmetické průměry	9
2.2	Nejvýznamnější světové indexy	9
2.3	Sektorové indexy	10
2.4	Měření výkonnosti investic	11
3	Charakteristika analýzy časových řad	14
3.1	Charakteristika časových řad	14
3.2	Testy stacionarity.....	15
3.2.1	Rozšířený Dickey – Fullerův test (ADF)	15
3.2.2	Phillips – Perron test	17
3.3	Model korekce chyb (ECM)	17
3.4	VEC modely	19
3.5	Kointegrační analýza	21
3.5.1	Engle – Granger test	22
3.5.2	Johansenův test.....	23
3.6	Testování heteroskedasticity a homoskedasticity	25
3.6.1	Grafická analýza.....	26
3.6.2	Whiteův test heteroskedasticity.....	27
3.7	Testování normality reziduí.....	28
3.7.1	Q-Q plot standardizovaných reziduí	30
3.7.2	Kolmogorov-Smirnovův test (KS test)	31
3.8	Testování autokorelace	32
3.9	Statistická verifikace modelu.....	36
3.9.1	Koeficient determinace	36
3.9.2	Korigovaný koeficient determinace	36
3.9.3	F-test.....	37
4	Testování kointegrace mezi vybranými akciovými indexy.....	38
4.1	Vstupní data.....	38
4.2	Přehled modelů	44

4.3	Výsledky testů stacionarity.....	45
4.4	Testování kointegrace.....	50
4.4.1	Před krizí	51
4.4.2	Během krize.....	53
4.4.3	Po krizi	55
4.5	Odhad VEC modelů.....	57
4.5.1	Před krizí	57
4.5.2	Během krize.....	59
4.5.3	Po krizi	61
4.6	Zobrazení kointegračních závislostí	63
4.6.1	Před krizí	63
4.6.2	Během krize.....	64
4.6.3	Po krizi	66
4.7	Statistická verifikace modelů.....	68
4.8	Zhodnocení a zdůvodnění výsledku vzájemné komparace odvětvových indexů.....	73
5	Závěr.....	74
	Seznam použité literatury.....	75
	Seznam zkratk	77
	Seznam příloh.....	2

1 Úvod

V nynějším globalizovaném světě mnoho investorů opouští investice na domácím trhu a snaží se maximalizovat svůj výnos na mezinárodním finančním poli. Jejich jediným cílem není jen maximalizace svých výnosů, ale také podstatná diverzifikace rizika. Toto riziko se snaží různými přístupy snížit na minimum. Jedna z nejčastějších možností je diverzifikace pomocí rozložení investice do více aktiv. K tomuto účelu jsou pro investory určené akciové indexy, které reprezentují daný koš aktiv. Akciové indexy v kombinaci s teritoriální diverzifikací investic do různých světových regionů se zdají být jednou z nejlepších variant diverzifikace, které mohou daní investoři dosáhnout. Přesto je nutné si uvědomit, že ani taková diverzifikace není zcela bezpečná, jak bylo dokázáno při celosvětovém propadu trhu napříč všemi světovými indexy během celosvětové finanční krize v roce 2008.

Cílem diplomové práce je zjistit, zdali je možné najít jiný způsob vhodné diverzifikace například pomocí sektorových indexů. K tomuto účelu bude využito zkoumání dlouhodobého rovnovážného vztahu mezi jednotlivými sektorovými indexy. Pro výzkum byly zvoleny zástupci tří sektorů: bankovní, potravinářský a automobilový. Z důvodu přehlednosti a snahy o co nejpřesnější výsledky byly dané indexy rozděleny do tří časových úseků. Data byla rozdělena do tří skupin, a to na období před krizí, během krize a po krizi. Tento mezisektorový vztah bude zkoumán pomocí kointegrace, která určí, zda je mezi jednotlivými sektory dlouhodobý rovnovážný vztah. Nejprve bude provedena analýza stacionarity časových řad, po které bude následovat samotný test kointegrace mezi časovými řadami.

Práce je rozdělena do pěti kapitol, včetně úvodu a závěru. V první kapitole jsou charakterizovány jednotlivé typy akciových indexů a způsoby jejich výpočtů. V druhé kapitole je popsána teoretická část diplomové práce zaměřena na analýzu časových řad a její metody a postupy.

Třetí kapitola diplomové práce obsahuje praktické zpracování jednotlivých cílů práce. Pomocí kointegrační analýzy je zkoumán dlouhodobý rovnovážný vztah mezi jednotlivými sektory. Vyhodnocení aplikační části a jejich výsledků je uvedeno v závěru práce.

2 Podstata akciových indexů

Akciové indexy slouží jako ukazatele vývoje daného trhu. Indexy vyjadřují historický a současný stav vývoje trhu. Pomocí těchto indexů lze pozorovat dlouhodobý vývoj trhu s jeho historickými tendencemi. Převážná část akciových, burzovních, či mimoburzovních trhů má svůj vlastní index.

2.1 Indexy

Jednotlivé indexy slouží jako reálný nástroj pro hodnocení stavu a vývoje daného kapitálového trhu. Indexy poskytují investorům informace o stavu kapitálového trhu jako celku, dílčí nebo sektorové indexy vypovídají o jeho částech. Indexy koncentrují pohyby cen mnoha jednotlivých akcií do jediného čísla a tak vypovídají o vývojových tendencích trhu. Díky koncentrovaným informacím poskytují indexy informace o současnosti a rovněž poskytují srovnání s minulostí. Z tohoto důvodu mohou být tyto informace použity pro předpoklad budoucího vývoje trhu.

Nejznámější světové indexy mají svou tradici daleko delší než 100 let. Jejich dostupnost a pravidelné zveřejňování v nejvýznamnějších sdělovacích prostředcích dokládá dostatečnou důvěru investorů, kteří jim věří a často se těmito indexy řídí.

Burzovní indexy se skládají z různých druhů a typů indexů. Jednotlivé indexy mohou být souhrnné a výběrové. Souhrnné indexy obsahují všechny akcie registrované a obchodované na dané burze. Takovým příkladem souhrnného indexu je burzovní index NASDAQ Composite, který obsahuje všechny akcie obchodované na trhu NASDAQ.

Výběrové indexy obsahují jen určité vybrané akcie. Příkladem takového výběrového indexu je index DJIA, který obsahuje akcie 30 společností registrovaných na NYSE. Tyto indexy se často používají jako benchmark pro srovnání jednotlivých výkoností akcií a investičních fondů za dané období.

Jednotlivé indexy se také odlišují tím, jak jsou kalkulovány. Indexy jsou nejčastěji kalkulovány dvěma způsoby. Jedním z možných výpočtů je použití obyčejného průměru. Druhý způsob může být využití systému váženého aritmetického průměru.

2.1.1 Obyčejné průměry

Vážené aritmetické nebo někdy také použité geometrické průměry, počítají pouze s aktuálním obdobím. Tyto průměry nepočítají s tržní kapitalizací jednotlivých akciových emisí. Tímto způsobem jsou vypočteny například indexy DJIA a Nikkei 225. Jednou z nevýhod takto vypočteného indexu je ten, že společnosti s vyšší tržní kapitalizací mají stejný vliv na hodnotu indexu jako společnosti s nižší tržní kapitalizací. V případě obyčejného aritmetického a geometrického průměru platí, že na vývoj těchto indexů má akcie s vysokou cenou větší vliv než akcie s nízkou cenou.

Může se tedy stát, že pokles akcie s vysokou cenou vyvolá větší pokles hodnoty indexu i tehdy, když cena ostatních akcií zahrnutých v indexu vzroste. Průměrování je běžné aritmetické, výjimečně může být i geometrické. Při aritmetickém průměrování se sečtou ceny jednotlivých akcií dle vzorce (2.1), jak uvádí Musílek [12].

$$Index = k_t \sum_{i=1}^n P_{i,t}, \quad (2.1)$$

kde:

$P_{i,t}$ = cena i-tého akciového titulu v čase t ,

k_t = koeficient v čase t (zajišťuje spojitost indexu při dělení a výměně akcií v indexu),

n = počet akciových titulů zahrnutých do indexu,

při obyčejném geometrickém průměrování se ceny jednotlivých akcií vynásobí a součin se poté umocní členem $1/n$, podle vzorce (2.2)

$$Index = k_t \sqrt[n]{\prod_{i=1}^n P_{i,t}}. \quad (2.2)$$

2.1.2 Vážené aritmetické průměry

Výpočet váženého aritmetického průměru je počítán z cen akcií, kde jednotlivými váhami je počet vydaných akcií zahrnutých do indexu. Příkladem může být index SP 500, jež obsahuje 500 akciových titulů. Dále například frankfurtský index DAX se počítá jako vážený aritmetický průměr 30 akciových společností, kde společnosti s vyšší tržní kapitalizací mají větší vliv na hodnotu indexu než společnosti s nižší tržní kapitalizací.

Dále zde pak patří indexy, jako jsou NASDAQ Composite, FTSE atd. Tyto indexy se počítají podle vzorce (2.3), dle Musílek [12],

$$Index = k_t \sum_{i=1}^n P_{i,t} n_{i,t}. \quad (2.3)$$

2.2 Nejvýznamnější světové indexy

Mezi nejvýznamnější americké indexy patří Standard & Poor's 500 (S&P 500), který obsahuje 500 akcií amerických společností. Tento akciový index S&P 500 je považován za nej přesnější ukazatel vývoje amerického akciového trhu. Navzdory tomu, že většina sdělovacích a informačních prostředků upřednostňuje zprávy o vývoji Dow Jones industrial average (DJIA).

Index Dow Jones industrial average představuje jeden z nejstarších indexů založených na obyčejném aritmetickém průměru. Index vytvořil v roce 1896 Charles Dow. Publikuje se od 26. května 1896. Tehdy obsahoval 12 akcií průmyslových podniků. Dnes jej tvoří 30 nejlepších společností na americkém trhu, tzv. akcie blue chips.

NASDAQ Composite zahrnuje všechny akcie obchodované na trhu NASDAQ, jedná se o více než 3000 společností. Index byl zaveden v roce 1971. Počítá se jako vážený průměr cen akcií. Počáteční hodnota indexu byla dne 5. února 1971 stanovena na 100 bodů. Svého maxima 5048 dosáhl 10. března 2000. Existuje také index NASDAQ 100, který obsahuje ceny jen sta největších nefinančních společností obchodovaných v NASDAQ.

Japonský index Nikkei 225 obsahuje 225 akcií obchodovaných v první sekci tokijské akciové burzy. Existuje od roku 1950 a počítá se jako obyčejný průměr cen akcií.

Evropský index Dow Jones Stoxx 50 obsahuje 50 akcií velkých evropských společností a index Dow Jones Euro Stoxx 50 zahrnuje 50 akcií velkých společností eurozóny. Oba indexy počítá společnost STOXX Limited, která je společným podnikem Deutsche Börse AG, Dow Jones a SWX Group.

Britský index Financial Times Stock Exchange 100 (FTSE 100, Footsie) obsahuje akcie 100 britských společností s nejvyšší tržní kapitalizací, jejichž akcie se obchodují na Londýnské akciové burze. Tržní kapitalizace těchto společností obsahuje asi 70% celkové tržní kapitalizace britského akciového trhu.

Německý index Deutscher Aktien-Index (DAX) obsahuje akcie 30 německých společností, s jejichž akciemi se obchoduje na frankfurtské burze. Výběr těchto akcií je prováděn na základě tržní kapitalizace a likvidity. Index byl zaveden v roce 1987.

V České republice byl při příležitosti prvního výročí burzy zaveden index PX 50 s výchozí úrovní na 1000 bodech. V roce 2006 byl tento index PX 50 nahrazen novým indexem PX. Index PX je cenovým indexem, kdy báze indexu se aktualizuje 4 krát ročně.

2.3 Sektorové indexy

Jak již bylo uvedeno dříve, pro zkoumání jednotlivých odvětví průmyslu jsou určeny sektorové indexy. Jednotlivá data sektorových indexů byla převzata od společnosti STOXX, zabývající se jejich výpočtem a denní aktualizací. Firma STOXX si rozdělila evropský sektor zahrnující Evropskou unii spolu s nečlenskými státy, nacházejícími se na území Evropy. Veškerá ekonomická činnost tohoto území byla rozdělena na 10 průmyslových odvětví. Z těchto deseti průmyslových odvětví je vypočteno 19 sektorových indexů, které v sobě odrážejí vývoj 41 odvětví složených ze 114 subsektorů.

2.4 Měření výkonnosti investic

Podkapitola 2.4 bude zaměřena na jednotlivé typy a druhy měření výkonnosti investic a s tím spojenými finančními ukazateli.

a) Měření zhodnocení

Měření zhodnocení je jednou z nejdůležitějších informací při hodnocení investice společně s měřením rizika. Vysoký příjem z investic bývá ve většině případů způsobený větším kolísáním hodnoty takové investice. V takových to případech by měli investoři sledovat nejen výši zhodnocení, ale také míru podstupovaného rizika.

Výnos investice vyjadřuje absolutní přírůstek investovaného kapitálu. Výnos investice by tedy měl být správně uváděn v peněžních jednotkách, nikoliv v procentech.

Výnosová míra představuje relativní přírůstek investovaného kapitálu. Výnosovou míru lze vypočítat jako podíl výnosu k investovanému kapitálu. Hodnota výnosové míry má být správně uváděna v procentech. Tato veličina vyjadřuje, o kolik procent se změnil kurz určitého aktiva během jednoho období. Měsíční změnu kurzu akcií můžeme vyjádřit pomocí vzorce 2.4. Dle Zmeškal [14].

$$R_t = \frac{P_{t+1} - P_t}{P_t} = \frac{\Delta P_t}{P_t}, \quad (2.4)$$

Ve vzorci 3.1 $R_{i,t}$ vyjadřuje měsíční diskretní výnos i -tého aktiva v procentech, $P_{i,t}$ je kurz i -té akcie v čase t a $P_{i,t-1}$ je kurz i -té akcie v čase $t-1$, tedy v předcházejícím období.

Průměrný výnos je celkový výnos investice uvedený v peněžních jednotkách, dělený počtem doby trvání investice.

Průměrná výnosová míra by měla být podle předchozích definic obdobně spočítána jako průměrný výnos, ale ne vždy to platí. Pro lepší vysvětlení problematiky bude uveden následující jednoduchý příklad.

Příklad 1.1

Pro názornost bude uveden jednoduchý příklad. Počáteční vklad do investice byl 500 000 CZK. První rok je investice úspěšná a vzroste o 100% na hodnotu 1 000 000 CZK. V druhém roce investice poklesne o 50 % na hodnotu 500 000 CZK. Po dvou letech investování je daná investice na počáteční hodnotě 500 000 CZK. Tedy za dva roky investice bylo dosaženo nulového výnosu a tak i průměrná roční výnosová míra musí být ve výši 0 %. Bohužel mnoho lidí pro výpočet průměrné výnosové míry používá jednoduchý aritmetický průměr, kdy investice v prvním roce dosáhla výnosové míry 100% a v druhém roce -50 %. Po dosazení do vzorce aritmetického průměru (2.1) získáme výpočet $((100-50)/2)$, jehož výsledek je 25 %. Tento výsledek je pak často špatně interpretován jako průměrná výnosová míra investice ve výši 25 %, přičemž při této hodnotě by měla být počáteční hodnota investice po dvou letech větší než na začátku. Výpočet průměrné výnosové míry aritmetickým průměrem je velice matoucí. V tomto jednoduchém příkladu je nesrovnalost jasně patrná. Avšak v případě akciových indexů, fondů a dluhopisů tento fakt na první pohled rozeznatelný rozhodně není. Jediným možným měřítkem skutečné průměrné roční výnosové míry je ukazatel CAGR.

■

CAGR (Compound annual growth rate) - českým ekvivalentem je vyjádření složená roční míra růstu. Ukazatel CAGR je v podstatě geometrický průměr koeficientů růstu zmenšený o jedničku. Jestliže nejsou k dispozici koeficienty růstu v jednotlivých letech, může být jejich součin ve vzorci rovněž substituován podílem počáteční a konečné hodnoty: $= (500\,000 \div 500\,000)^{0,5} - 1 = 0$. Aritmetický průměr oproti CAGRu skutečnou roční výnosovou míru nadhodnocuje.

b) Měření rizika

Riziko jednotlivých investic je měřeno jako odchylka jednotlivých výnosových měř investice. Tento jev můžeme nazvat volatilitou. Toto riziko aktiv, jakými jsou akcie, dluhopisy atd. je možné měřit pomocí směrodatné odchylky. Směrodatná odchylka charakterizuje riziko daného aktiva. Vypočítáme ji jako druhou odmocninu z rozptylu výnosů akcie podle vzorce 2.5.

$$\sigma_i = \sqrt{\sigma_i^2}, \quad (2.5)$$

Ve vzorci 3.4 je σ_i směrodatná odchylka akcie a σ_i^2 rozptyl výnosů aktiv.

Shape Ratio

Ukazatel Sharpe Ratio je souhrnný ukazatel, který dává do poměru míru zhodnocení a míru rizika, kterou daný fond během let dosáhl. Dle tohoto ukazatele je výhodnější ta investice, jejíž poměr výnosu nad bezrizikovou mírou a rizikem (danou směrodatnou odchylkou) je vyšší. Jde tedy o míru premie k podstoupenému riziku. Čím je výsledné číslo vyšší, tím je výnos, kterého dosáhla investice na jednotku rizika, vyšší. Jednou z nevýhod Sharpeho Ratio je, že nebere v potaz asymetričnost rizika. To znamená, že daná investice, která zaznamená pouze jeden výraznější pokles na konci sledovaného období, bude mít lepší Sharpeho Ratio, než investice s průměrným rizikem. Další jeho nevýhodou je, že negativně hodnotí nejenom volatilitu při poklesu, ale také volatilitu při růstu. Chan [8].

Sortino Ratio

Sortino ratio je upravený ukazatel Sharpe ratio. Tento ukazatel vyvinul Frank Sortino, který na rozdíl od ukazatele Sharpe Ratio bere při výpočtu v úvahu pouze volatilitu při poklesu. Toto riziko poklesu představuje pro investory riziko ztráty. Ve výpočtu figurují stejné veličiny, jako u výpočtu Sharpe Ratia, ale riziko představuje pouze volatilita vypočtená jako směrodatná odchylka výnosu nad bezrizikový výnos zachycující pouze poklesy.

c) Diverzifikace

Z důvodu snahy dosáhnout co nejlepších ukazatelů výnosu a rizika jsou správci investic nuceni maximalizovat zhodnocení a minimalizovat podstupovaná rizika. K tomuto účelu slouží diverzifikace. Diverzifikací se rozumí rozložení rizik mezi více aktiv, čímž vznikají portfolia. Diverzifikace se provádí dle různých možností a kritérií. Diverzifikovat lze například nákupem více rozdílných aktiv z různých oblastí, kde jsou aktiva obchodována. Cílem diplomové práce bude zjistit, zda je možné diverzifikovat i nákupem aktiv z různých ekonomických sektorů.

3 Charakteristika analýzy časových řad

Základním prostředkem statistické analýzy je zkoumání časových řad. Časovými řadami jsou označovány jednotlivé závislé proměnné veličiny Y , jež jsou uvažovány jako funkce času. Časovou řadu lze také charakterizovat jako množinu pozorování kvantitativní charakteristiky uspořádanou v čase.

Rozdělení časových řad je možné, podle charakteru ukazatele, na časové řady okamžikové (hodnoty jsou zaznamenány k určitému časovému okamžiku), intervalové (počet událostí, které se nashromáždily za určitý časový interval) nebo podle periodicity na krátkodobé (periodicita kratší než 1 rok) a dlouhodobé (periodicita nejméně 1 rok).

3.1 Charakteristika časových řad

Zkoumání vývoje časových řad má několik podob. Absolutní charakteristiky umožňují absolutní porovnání hodnot jednotlivých členů řady.

Absolutní přírůstky (1. Diference)

$$Y = Y_t - Y_{t-1}. \quad (3.1)$$

Relativní – koeficienty růstu

$$K_t = \frac{Y_t}{Y_{t-1}}. \quad (3.2)$$

Tempo růstu – koeficient růstu v procentech

$$K_t = \frac{Y_t}{Y_{t-1}} \times 100. \quad (3.3)$$

3.2 Testy stacionarity

U časových řad lze sledovat mnoho vlastností. Jednou z nich může být právě stacionarita. Časové řady rozdělujeme na stacionární a nestacionární, přičemž stacionární časovou řadou rozumíme takovou časovou řadu, jejíž průměr či variabilita se pro různé úseky časové řady nemění. Lze též mluvit o takzvané řadě s krátkou pamětí. Opakem stacionárních časových řad jsou časové řady nestacionární, které taktéž lze označit jako časové řady s dlouhou pamětí.

Základním předpokladem pro kointegrační analýzu je požadavek, aby dané časové řady byly nestacionární. Z tohoto důvodu je prvním krokem kointegrační analýzy testování stacionarity daných časových řad. K testování stacionarity existuje mnoho různých testů. V této diplomové práci budou popsány dva testy. Prvním testem je rozšířený Dickey-Fullerův test a druhý test bude Philips-Perronův test. Tyto testy budou provedeny v programu EViews.

3.2.1 Rozšířený Dickey – Fullerův test (ADF)

U časových řad určíme takzvaný řád integrovaného procesu, který obecně označujeme jako $I(d)$. Pro stacionární řady je $d=0$, tedy se jedná o integrovaný proces řádu 0. Pro nestacionární řady je $d > 0$. Pokud se nestacionární řada po aplikaci difference prvního řádu stává řadou stacionární, tak danou nestacionární řadu označujeme $I(1)$. Necht' máme nestacionární časovou řadu y_t , pak diferenci prvního řádu spočítáme jako:

$$\Delta y_t = y_t - y_{t-1}, \quad (3.4)$$

$$\Delta^2 y_t = \Delta(\Delta y_t) = \Delta(y_t - y_{t-1}) = \Delta y_t - \Delta y_{t-1} = y_t - 2y_{t-1} + y_{t-2}, \quad (3.5)$$

$$\Delta^k y_t = \Delta^{k-1}(\Delta y_t), \text{ pro } k \in N = 2, 3, \dots, n. \quad (3.6)$$

Nejmenší k , pro které se k -tý diferenciál časové řady y_t stává stacionární časovou řadou, označujeme jako řád d . Časová řada y_t je pak $I(d)$. Obecně ekonomické časové řady bývají běžně typu $I(1)$.

Klasický DF test funguje pouze pro časové řady, jejichž reziduální složka ε_t představuje bílý šum. Ale Δy_t může obsahovat autokorelovanost, která nemusí být dostatečně zachycena v modelu. Proto používáme rozšířený DF test, který uvažuje pro časovou řadu

$$y_t = \beta y_{t-1} + \varepsilon_t, \quad (3.7)$$

tvarem diferencované časové řady

$$\Delta y_t = \phi y_{t-1} + \sum_{i=1}^p \alpha_i \varepsilon_t \Delta y_{t-1} + \varepsilon_t, \quad (3.8)$$

kde p je počet zpoždění a

$$\phi = -(1 - \sum_{i=1}^p \alpha_i) \text{ a } \alpha_i = \sum_{j=1}^p \alpha_j. \quad (3.9)$$

Zahrnutí zpoždění do modelu umožňuje zajistit, aby reziduální složka ε_t nebyla autokorelovaná, tedy aby se jednalo o bílý šum.

DF test testuje hypotézu

$$H_0: \phi = 0, \quad (3.10)$$

$$H_1: \phi < 0 \quad (3.11)$$

Testovanou statistikou je

$$DF = \frac{\hat{\phi}}{\hat{\sigma}(\hat{\phi})}, \quad (3.12)$$

kde DF se řídí Dickey – Fullerovým rozdělením.

Tutíž hypotézu H_0 můžeme formulovat různými způsoby. Například $H_0: \phi = 0$ je totéž, jako hypotézy ve tvaru, řada obsahuje jednotkový kořen nebo, že řada je nestacionární nebo, že $y_t \sim I(1)$. Alternativa H_1 by pak byla formulovaná jako $\phi < 0$ nebo, že řada neobsahuje jednotkový kořen nebo, že řada je stacionární nebo, že $y_t \sim I(0)$.

Nevýhodou tohoto testu je jeho malá síla. To znamená, že test může nezamítnout hypotézu H_0 o přítomnosti jednotkového kořene, přestože by měl.

DF testuje přítomnost jednotkového kořene, ale už neuvažuje o možnosti, že by v modelu mohl být víc než jeden jednotkový kořen. Proto se v případě DF testu postupuje tak, že pokud nedojde k zamítnutí hypotézy H_0 o přítomnosti jednotkového kořene, provede se difference časové řady y_t a tato nová časová řada Δy_t se otestuje DF testem na přítomnost jednotkového kořene. Pokud opět nedojde k zamítnutí hypotézy H_0 , pak se řada Δy_t opět diferencuje a nová řada se opět testuje DF testem. Tento postup se opakuje, dokud nedojde k zamítnutí hypotézy H_0 ve prospěch alternativní hypotézy. Tím nám DF test pomůže určit řád d časové řady y_t .

3.2.2 Phillips – Perron test

Tento test řadíme mezi neparametrické testy, tedy takové, na jejichž vstupní data nejsou kladeny žádné požadavky, jako může být například normalita apod. Jedná se o velmi podobný test, jako je DF test. Hypotéza H_0 a H_1 avšak je založena na jiné testové statistice.

Více se o tomto testu lze dočíst viz Davidson [4].

3.3 Model korekce chyb (ECM)

Na úvod musíme zdůraznit, že se nejedná o model, který by nějakým způsobem opravoval chyby jiného modelu, jak se dle názvu může zdát, ale jedná se o kategorii modelů časových řad, které dokážou přímo odhadnout rychlost, se kterou se závislá proměnná x vrací do rovnovážného stavu po určité změně nezávislé proměnné y .

Tyto modely se hodí jak k popisu krátkodobých, tak k popisu dlouhodobých vztahů mezi časovými řadami. Dokonce je lze využít pro data, která má smysl vyhodnocovat pomocí kointegrační analýzy, tak i pro data, která jsou stacionární.

Pro pochopení, jak zhruba ECM (Error Correction Models) modely fungují, bude uveden jednoduchý příklad.

Příklad 1.2

Předpokládejme, že máme dvě časové řady x_t a y_t , přičemž x_t reprezentuje výdej v domácnosti a y_t příjem domácnosti. Je zjištěno, že časové řady jsou ve vzájemném vztahu, kdy výdaje domácnosti představují 90% příjmu domácnosti, tedy

$$x_t = 0,9 \cdot y_t. \quad (3.13)$$

Tímto vztahem reprezentujeme dlouhodobý rovnovážný vztah mezi příjmem a výdajem domácnosti. Dále je zjištěno, že dojde-li ke změně příjmu, pak změna výdajů odpovídá 50% změně příjmu, tedy


$$\Delta x_t = 0,5 \cdot \Delta y_t. \quad (3.14)$$

Tímto vztahem naopak charakterizujeme krátkodobý vztah mezi příjmem a výdajem domácnosti. A nakonec také je předpokládáno, že systém má tendenci vracet se do svého dlouhodobého rovnovážného stavu s každou periodou o 20 %. Tedy nakonec může být změna ve výdajích domácnosti zapsána jako

$$\Delta x_t = 0,5 \cdot \Delta y_t - 0,2 \cdot (x_{t-1} - 0,9 \cdot y_{t-1}) + \varepsilon_t. \quad (3.15)$$

Na grafu níže jsou zobrazeny dvě časové řady, kde zelená reprezentuje příjmy domácnosti a červená výdaje. Zpočátku se nacházíme v rovnovážném stavu. Příjmy i výdaje jsou v čase konstantní. Dojde-li ke změně v příjmech v časový okamžik t , v tomtéž okamžiku se projeví krátkodobý vliv a výdaje se změní o polovinu změny příjmu (3.14). Příjmy po této změně budou nějakou dobu opět konstantní a výdaje tak mají čas se postupně srovnat do rovnovážné polohy (3.13). Pokud by docházelo k častějším změnám v příjmech, pak by výdaje do rovnovážného vztahu konvergovaly značně pomaleji.

Graf č. 3.1 – Průběh návratu příjmů a výdajů do dlouhodobé rovnováhy



Zdroj: Vlastní zpracování v programu Matlab

3.4 VEC modely

VEC modely (Vector Error Correction Models) mají velké uplatnění při kointegrační analýze a to konkrétně v testování kointegračních vztahů pomocí Johansenova testu.

Pro jednoduchost bude nejprve zaměřena analýza pouze na jednu časovou řadu y_t . Pokud bude chtěno pro tuto časovou řadu sestavit VEC model, v první řadě bude muset být vycházeno z VAR modelu. VAR model obsahuje soubor m proměnných časové řady y_t (záleží na počtu zpoždění p) a počet zahrnutých zpoždění p . Bude tak získána soustava m rovnic, které může být vektorově zapsána, takto:

$$y_t = A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + \varepsilon_t, \quad (3.16)$$

kde y_t je m rozměrný vektor a A_i , pro $i=1,2,\dots,p$, jsou matice koeficientů dané soustavy. Pro zjednodušení bude uveden příklad 1.3..

Příklad 1.3

Je daná časová řada y_t , jejíž hodnoty jsou $\{2, 4, 1, 2, -13, -15\}$. Příslušný VAR($p=3$) je

$$2 = \beta_1 + 4\beta_2 + 2\beta_3$$

$$-13 = 2\beta_1 + \beta_2 + 4\beta_3$$

$$-15 = -13\beta_1 + 2\beta_2 + \beta_3$$

V souladu s rovnicí (3.16) je:

$$y_t = \begin{bmatrix} 2 \\ -13 \\ -15 \end{bmatrix}, y_{t-1} = \begin{bmatrix} 1 \\ 2 \\ -13 \end{bmatrix}, y_{t-2} = \begin{bmatrix} 4 \\ 1 \\ 2 \end{bmatrix}, y_{t-3} = \begin{bmatrix} 2 \\ 3 \\ 1 \end{bmatrix}$$

$$A_1 = \begin{bmatrix} \beta_1 & 0 & 0 \\ 0 & \beta_1 & 0 \\ 0 & 0 & \beta_1 \end{bmatrix}, A_2 = \begin{bmatrix} \beta_2 & 0 & 0 \\ 0 & \beta_2 & 0 \\ 0 & 0 & \beta_2 \end{bmatrix}, A_3 = \begin{bmatrix} \beta_3 & 0 & 0 \\ 0 & \beta_3 & 0 \\ 0 & 0 & \beta_3 \end{bmatrix}.$$

■

VEC model k příslušné časové řadě y_t , jejíž VAR model je dán rovnicí (3.16) má tvar

$$\Delta y_t = \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + \Gamma_2 \Delta y_{t-2} + \dots + \Gamma_{p-1} \Delta y_{t-(p-1)} + \varepsilon_t, \quad (3.17)$$

kde $\Pi = (\sum_{i=1}^p A_i) - I$ a $\Gamma_i = -(\sum_{j=i+1}^p A_j)$. I je jednotková matice. Tedy matice, která má na diagonále jedničky.

Příklad 1.4

Nyní uvažujme pouze jednu hodnotu časové řady y_t ze vztahu (3.16) s $p=2$. Pak bude získána jedna rovnice

$$y_t = \beta_1 y_{t-1} + \beta_2 y_{t-2} + \varepsilon_t.$$

Postupným odvozováním lze získat příslušný VEC model následovně

$$\begin{aligned} \Delta y_t &= y_t - y_{t-1} + \varepsilon_t = (\beta_1 y_{t-1} + \beta_2 y_{t-2}) - y_{t-1} + \beta_2 y_{t-1} + \varepsilon_t \\ &= (\beta_1 + \beta_2 - 1)y_{t-1} - \beta_2(y_{t-1} - y_{t-2}) + \varepsilon_t \\ &= (\beta_1 + \beta_2 - 1)y_{t-1} - \beta_2 \Delta y_{t-1} + \varepsilon_t, \end{aligned}$$

kde $\Pi = (\beta_1 + \beta_2 - 1)$.

■

Pokud budou dvě časové řady y_t a x_t , pak příslušné modely jsou následující:

VAR: rovnice

$$y_t = \beta_{y0} + \beta_{yy1}y_{t-1} + \dots + \beta_{yyp}y_{t-p} + \beta_{yx1}x_{t-1} + \dots + \beta_{xyp}x_{t-p} + \varepsilon_t \quad (3.18)$$

$$x_t = \beta_{x0} + \beta_{xy1}y_{t-1} + \dots + \beta_{xyp}y_{t-p} + \beta_{xx1}x_{t-1} + \dots + \beta_{xxp}x_{t-p} + \varepsilon_t \quad (3.19)$$

VEC: rovnice

$$\begin{aligned} \Delta y_t &= \beta_{y0} + \beta_{y1}\Delta y_{t-1} + \dots + \beta_{yp}\Delta y_{t-p} + \gamma_{y1}\Delta x_{t-1} + \dots \\ &\quad + \gamma_{yp}\Delta x_{t-p} - \lambda(y_{t-1} - \alpha_0 - \alpha_1 x_{t-1}) + \varepsilon_t \end{aligned} \quad (3.20)$$

$$\begin{aligned} \Delta x_t &= \beta_{x0} + \beta_{x1}\Delta y_{t-1} + \dots + \beta_{xp}\Delta y_{t-p} + \gamma_{x1}\Delta x_{t-1} + \dots \\ &\quad + \gamma_{xp}\Delta x_{t-p} - \lambda(y_{t-1} - \alpha_0 - \alpha_1 x_{t-1}) + \varepsilon_t \end{aligned} \quad (3.21)$$

3.5 Kointegrační analýza

Kointegrace vyjadřuje dlouhodobý rovnovážný stav mezi dvěmi, či více proměnnými. Tento dlouhodobý rovnovážný stav se vytváří kombinací dvou či více časových řad, jenž popisuje takový vztah rovnicí (3.22), dle Mills, Markellos [11],

$$y_t = a \cdot x_t, \quad (3.22)$$

kde y_t je vysvětlovaná proměnná, x_t je vysvětlující proměnná a a představuje konstantu. Pokud se jednotlivé veličiny pohybují v dlouhodobém rovnovážném vztahu, mohou nastat období, kdy v krátkém období nemusí být spolu v rovnovážném vztahu. Avšak jak tvrdí Cipra [3], dlouhodobá nerovnováha, například u proměnných představujících tržní prostředí jako u akcií, komodit či jiných aktiv, by mohla tato skutečnost vést k arbitrážním příležitostem. Tohoto faktu se snaží využít celá řada obchodníků, zabývajících se statistickými arbitrážemi.

Kointegrační vztahy a jejich analýzy jsou často popisovány pomocí modelu VAR. Tuto skutečnost popisuje Cipra [3] na příkladu dvourozměrného modelu VAR, jehož dvě časové řady jsou typu $I(1)$, ale jejich vzájemná kombinace v modelu má pouze jeden jednotkový kořen, který je stacionární, což v praxi znamená, že dané časové řady jsou kointegrované.

Testování dlouhodobého stavu rovnováhy probíhá na základě testů, které stanoví počet kointegračních vztahů v daném modelu VAR. K potvrzení modelu VAR dojde v případě, že existuje alespoň jeden takový dlouhodobý stav rovnováhy. Mezi nejznámější testy patří např. Engle-Granger test nebo Johansenův test. Tyto testy budou použity pro účely kointegrační analýzy v praktické části diplomové práce.

3.5.1 Engle – Granger test

Jednou z dalších metod, které se zabývají testováním kointegrace, je Engle-Grangerova metoda. Jedná se o metodu, kterou navrhli Engle a Granger (1987). Tato metoda testuje, zda mezi dvěma časovými řadami y_t a x_t existuje kointegrace. Aby časové řady byly kointegrované, musí být nestacionární. Předpokládáme, že obě řady patří $I(d)$. Pro jednoduchost předpokládejme, že jsou řady z třídy $I(1)$, tedy řady s jednotkovým kořenem. Pokud jsou řady stacionární, pak nemohou být kointegrované.

Za pomoci regresní analýzy odhadneme β koeficienty β_0 a β_1 a rezidua ε_t v rovnici

$$y_t = \beta_0 + \beta_1 x_t + \varepsilon_t, \quad (3.23)$$

pokud mezi řadami existuje kointegrace, pak časová řada ε_t musí být stacionární. Tedy např. pomocí DF testu, budeme testovat hypotézu.

$$H_0 : \varepsilon_t \sim I(1) \rightarrow \text{řady nejsou kointegrované} \quad (3.24)$$

$$H_1 : \varepsilon_t \sim I(0) \rightarrow \text{řady jsou kointegrované} \quad (3.25)$$

Jediný rozdíl je, že pro DF statistiku nejsou použity kritické hodnoty stejné jako u DF testu, protože jsou již provedeny ve vztahu (3.23) odhad pomocí regresní analýzy a tím je dopuštěno větší chyby než normálně, ale Engle a Granger vytvořili novou tabulku kritických hodnot, které jsou pro tento test vhodnější. Tyto hodnoty jsou uvedeny společně s výpočty v programu EViews.

3.5.2 Johansenův test

Tento test testuje kointegraci obecně mezi několika časovými řadami typu $I(1)$. Zatímco Engle-Grengerův test lze použít pouze v případě, kdy uvažujeme jen dvě časové řady a tedy je zde možný buď žádný nebo jeden kointegrační vztah, Johansenův test připouští existenci i více než jednoho kointegračního vztahu (je-li n nestacionárních časových řad typu $I(1)$, pak zde může existovat až $n-1$ kointegračních vztahů).

Johansenův test je v kointegrační analýze jeden z nepoužívanějších testů, protože např. na rozdíl od Engle-Grengerova testu nevychází z ADF, který už sám vykazuje nízkou sílu testu, ale je založen na tzv. VEC modelu.

$$\Delta y_t = \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + y_{t-1} + \Gamma_2 \Delta y_{t-2} + \dots + \Gamma_{p-1} \Delta y_{t-(p-1)} + \varepsilon_t, \quad (3.26)$$

kde $\Pi = (\prod_{i=1}^p A_i) - I$ a $\Gamma_1 = -(\prod_{j=i+1}^p A_j)$. Předmětem zájmu je matice Π . U matice Π bude předmětem zkoumání její hodnota, která odpovídá počtu kointegračních vektorů. Jsou zde tři možnosti:

1. $h(\Pi) = 0$. Matice má nulovou hodnotu, takže $\Pi = 0$. Rovnice (3.26) bude ve tvaru
$$\Delta y_t = \Gamma \Delta y_{t-1} + \Gamma_2 \Delta y_{t-2} + \dots + \Gamma_{p-1} \Delta y_{t-(p-1)} + \varepsilon_t \quad (3.27)$$

Z toho vyplývá, že zde není žádný kointegrační vztah.

2. $h(\Pi) = n$. Matice má plnou hodnotu y_t neobsahuje jednotkový kořen a y_t je tedy stacionární $I(0)$. Časová řada nesplňuje předpoklad nestacionarity pro kointegrační analýzu.
3. $0 < h(\Pi) = m < n$. V tomto případě jsou zde kointegrační vztahy. Jako hodnota matice označujeme m .

K výpočtu hodnoty matice $h(\Pi)$ se využívají charakteristické polynomy, na jejímž základu se určují vlastní čísla matice λ_i . Pro další výpočty se předpokládá, že vlastní čísla jsou seřazena $1 \geq \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$. Pokud zde nejsou žádné kointegrační vztahy, budou všechna vlastní čísla nulová, což odpovídá tomu, že hodnota matice je rovna nule. Johansenův test testuje počet vlastních čísel, které se statisticky významně liší od nuly. Běžně se používají dva postupy Johansenova testu.

1. λ_{trace}

$$\lambda_{trace}(r) = -T \sum_{i=r+1}^n \ln(1 - \hat{\lambda}_i), \quad (3.28)$$

kde T odpovídá počtu pozorování a r je počet kointegračních vztahů. Je testována nulová hypotéza, že počet kointegračních vztahů odpovídá nejvýše r . Vůči alternativě, že počet kointegračních vztahů je větší než r .

2. λ_{max}

$$\lambda_{max}(r, r + 1) = -T \ln(1 - \hat{\lambda}_{r+1}), \quad (3.29)$$

Kde T je opět počet pozorování a r počet kointegračních vztahů. Zde se testuje nulová hypotéza, že počet kointegračních vztahů je roven r vůči alternativě, že počet kointegračních vztahů je $r+1$. Kritické hodnoty těchto testů lze nalézt v Statistical tables for economists [22].

3.6 Testování heteroskedasticity a homoskedasticity


Heteroskedasticita představuje problematiku měnícího se rozptylu náhodné složky u_t . To znamená, že rozptyl náhodné složky není konstantní v čase. Opačným, zato žádoucím, jevem je tzv. homoskedasticita, která představuje konstantní rozptyl náhodné složky u_t .

Důvodem objevující se heteroskedasticity je zpravidla průřezová regresní analýza nehomogenních jednotek, kdy se mezi těmito jednotkami vyskytují značně velké rozdíly. Dále jsou důvodem odlehlá pozorování (outliers), chybná specifikace modelu, výskyt chyby měření dat nebo nevhodná transformace dat, Hančlová [6].

Testování heteroskedasticity obvykle zprvu spočívá v grafické analýze. Pak zpravidla následuje vybraný adekvátní test, např. Whiteův zobecněný test, Goldfeldův-Quandtův test apod.

Vývoj standardizovaných reziduí v čase znázorňuje Graf 3.1 Pro účely tohoto grafu je však nutné splnit následující podmínky. Rezidua by se s 95% pravděpodobností měla pohybovat uvnitř konfidenčního intervalu, tzn. v intervalu $<-1,96; 1,96>$. A dále se rezidua v konfidenčním intervalu musí pohybovat náhodně, a to kolem nulové hodnoty, tzn. bez systematických změn a cyklických výkyvů.

Graf 3.1 Vývoj standardizovaných reziduí



Zdroj: Vlastní zpracování


Z grafu je patrné, že obě výše stanovené podmínky jsou splněny. Všechna rezidua se po celé sledované období pohybují v rámci konfidenčního intervalu a náhodně se pohybují kolem 0 bez jakýchkoli cyklických výkyvů.

3.6.1 Grafická analýza

Pro účely grafické analýzy testování heteroskedasticity je nutné do modelu zavést novou proměnnou, a to ZRE_2 (druhá mocnina standardizovaných reziduí). Tato proměnná v programu SPSS je zavedena následujícím způsobem: Transform → Compute Variable → $ZRE_2 = ZRE_1 * ZRE_1$.

Obecně platí, že hodnota této nové proměnné vždy leží na ose y, přičemž na ose x se střídají jednotlivé nezávislé proměnné. Dále je stanovena příslušná hodnota rozhodující o vyskytující se heteroskedasticitě respektive homoskedasticitě v daném modelu. Tato hodnota se pohybuje na úrovni 3,84. Pokud se hodnoty pohybují pod touto hodnotou (v grafu linií, přípustnost 5 %), pak se v daném modelu heteroskedasticita nevyskytuje. Pro účely vytvoření tohoto grafu je využit program SPSS, přičemž postup je následující: Graphs → Scatter/Dot → Simple → (ZRE_2, Unstandardized Predicted Value).

Graf 3.2 Testování heteroskedasticity náhodného modelu



Zdroj: Vlastní zpracování v programu SPSS

Z grafů je patrné, že se na ose y vždy vyskytuje stejná proměnná, a to ZRE_2. Jedná se o nově zavedenou proměnnou. Naopak na ose x se proměnná vždy mění. Graf 3.2 představuje testování heteroskedasticity v celém modelu, s použitím nestandardizované predikované proměnné (PRE_1). Důležitým poznatkem je fakt, že graf vypovídá o všech proměnných.

Z grafu je dále zřejmé, že podmínka o rozložení hodnot proměnných pod stanovenou hranicí je splněna, a to i bez využití případných 5 % nad hranicí. Všechny hodnoty se totiž pohybují v rámci konfidenčního intervalu a žádná z něj nevybočuje. Lze tedy předpokládat, že se v modelu nevyskytuje heteroskedasticita, nýbrž žádoucí homoskedasticita. Tato skutečnost však musí být potvrzena, s výjimkou grafického testu, také jiným způsobem. K tomuto účelu se často využívá tzv. Whiteův zobecněný test.

3.6.2 Whiteův test heteroskedasticity

Whiteův obecný test je založen na získání nestandardizované reziduální složky \hat{u}_t a výpočtu jejího čtverce \hat{u}_t^2 . Rezidua jsou stanovena dle daného modelu, přičemž jsou vysvětlována dalšími vysvětlujícími proměnnými X_1 a X_2 a jejich rozšířením o další parametry, jimž jsou X_{12} ($X_1 \cdot X_1$), X_{22} ($X_2 \cdot X_2$) a $X_1 \cdot X_2$. Tento postup je však platný pouze pro model s dvěma vysvětlujícími proměnnými. Obecná rovnice je pak dána vztahem,

$$\hat{u}_t^2 = \alpha_0 + \alpha_1 \cdot X_{1i} + \alpha_2 \cdot X_{2i} + \varepsilon_i . \quad (3.30)$$

Hypotézy:

H0: v modelu se vyskytuje homoskedasticita, tzn., že všechny koeficienty alfa jsou současně rovny nule.

H1: v modelu se vyskytuje heteroskedasticita, tzn., že všechny koeficienty alfa nejsou současně rovny nule.

Z tohoto modelu lze pak získat hodnotu determinačního koeficientu R^2 .

Rozhodovací pravidlo:

Platí-li $n \cdot R^2 > \chi^2_{2\alpha}(\text{df})$, pak zamítáme hypotézu H0 (přijímáme H1).


Výsledný koeficient determinace je tedy vynásobený počtem pozorování a porovnán s kritickou hodnotou, kterou lze opět získat v programu Excel pomocí funkce CHIINV (α ; df). Předpokladem je hladina významnosti 5 %.

3.7 Testování normality reziduí

V tomto případě se jedná o testování předpokladu, že náhodná složka (u) má normální „Gaussovo rozdělení“ se střední hodnotou rovnou nule. Normalitu reziduí je možno testovat pomocí grafů (histogram, P-P plot, Q-Q plot) či pomocí neparametrických testů (např. JB test, KS test).

Histogram rozdělení četností reziduální složky slouží zpravidla k vizuálnímu posouzení empirického rozdělení četností s teoretickou Gaussovou křivkou hustoty pravděpodobnosti, což zobrazuje Graf 3.3 histogram standardizovaných reziduí. Jak vypovídá tabulka 3.1, S (skewness = šikmost) = -0,447, což signalizuje negativní zešikmení a K (kurtosis = špičatost) = 0,913, což naznačuje vysokou špičku. Tento graf byl vytvořen pomocí programu SPSS takto: Graphs → Legacy dialogs → Histogram → Standardized Residual → display normal curve.

Graf. 3.3 Histogram ZRE_1 náhodného modelu



Zdroj: Vlastní zpracování v programu SPSS

Tab. 3.1: Deskriptivní statistika náhodného modelu

Descriptive Statistics					
	N	Skewness		Kurtosis	
	Statistic	Statistic	Std. Error	Statistic	Std. Error
Standardized Residual	47	-,447	,347	,913	,681
Valid N (listwise)	47				

Zdroj: Vlastní zpracování v programu SPSS

V SPSS byla tato tabulka vytvořena: Analyze → Descriptive Statistics → Variables (Standardized Residuals) → Options (Skewness, Kurtosis).

P-P plot standardizovaných reziduí představuje graf porovnávající teoretické kumulativní četnosti na ose y a empirické kumulativní pravděpodobnosti na ose x pro reziduální složky. Ideální vývoj se předpokládá na ose 45 stupňů. Čím více hodnoty přiléhají k dané přímce, tím více se blíží normálnímu rozdělení, dle Hančlová [6].

Tento graf lze vytvořit v programu SPSS následovně: Analyze → Descriptive Statistics → P-P plots → Variables (Standardized Residuals). Příslušný P-P plots uvádí Graf 3.4.

Graf 3.4: P-P Plots ZRE_1 náhodného modelu



Zdroj: Vlastní zpracování v programu SPSS


Z grafu je evidentní, že žádná hodnota se extrémně nevychyluje od přímky v úhlu 45 stupňů, všechny uvedené hodnoty se pohybují těsně v její blízkosti. Lze tedy předpokládat, že rozdělení reziduí je normální.

3.7.1 Q-Q plot standardizovaných reziduí

Q-Q plot graf standardizovaných reziduí představuje jakousi obdobu P-P plotu, přičemž platí, že se na místo kumulativních četností na ose y porovnávají teoretické a empirické kvantily. Opět platí, že čím blíže jsou hodnoty dané přímce, tím více se blíží normálnímu rozdělení, dle Hančlová [6].

V programu SPSS se dá vytvořit následovně: Analyze → Descriptive Statistics → Q-Q plots → Variables (Standardized Residuals). Příslušný graf Q-Q plots uvádí Graf 3.5.

Graf 3.5 Q-Q Plots ZRE_1



Zdroj: Vlastní zpracování v programu SPSS

V grafu je vidět, že žádná hodnota se extrémně nevychyluje od přímky v úhlu 45 stupňů, všechny uvedené hodnoty se pohybují těsně v její blízkosti. Lze tedy předpokládat, že rozdělení reziduí je normální.

3.7.2 Kolmogorov-Smirnovův test (KS test)

Kolmogorovův-Smirnovův test (KS test) již není grafickou metodou testování normalit reziduí. Jedná se o jeden z neparametrických testů, přičemž všechny výsledky vycházejí ze stanovení určitých hypotéz.

H0: distribuční funkce rozdělení náhodného výběru $F_n(x)$ odpovídá teoretické distribuční funkci.

H1: distribuční funkce rozdělení náhodného výběru $F_n(x)$ neodpovídá teoretické distribuční funkci.

Rozhodovací pravidlo:

Platí-li $\text{sign}_{\text{vyp}} > \text{sign}_{\text{krit}}$, pak zamítáme hypotézu H1 (přijímáme H0).

Základním kritériem tohoto testu jsou rozdíly mezi teoretickou a empirickou distribuční funkcí. Porovnává se zde sign_{vyp} se $\text{sign}_{\text{krit}}$ na stanovené hladině významnosti 5%.

Pro stanovení hodnoty sign_{vyp} je využito programu SPSS tímto způsobem: Analyze → Nonparametric tests → Legacy dialogs → Sample K-S. Výsledkem je tabulka č. 3.2.

Tabulka 3.2 K-S test náhodného modelu

One-Sample Kolmogorov-Smirnov Test		Standardized Residual
N		48
Normal Parameters ^{a,b}	Mean	,0000000
	Std. Deviation	,97849211
	Absolute	,101
Most Extreme Differences	Positive	,101
	Negative	-,061
Test Statistic		,101
Asymp. Sig. (2-tailed)		,200 ^{c,d}

Zdroj: Vlastní zpracování v programu SPSS

Z tabulky je patrné, že signvyp odpovídá hodnotě 0,200, což je hodnota vyšší než 0,05. Lze tedy konstatovat, že hypotéza H_1 je zamítnuta a přijímáme hypotézu H_0 . Distribuční funkce rozdělení standardizovaných reziduí tak odpovídají normálnímu rozdělení na 5% hladině významnosti.

3.8 Testování autokorelace

Autokorelace představuje sériovou závislost reziduálních složek na svých zpožděných hodnotách, jejíž příčinou může být mnoho skutečností. Mezi ně například patří setrvačnost ve vývoji ekonomických veličin, chybná specifikace modelu, chyby měření, nesprávně nastavené zpoždění u vysvětlujících proměnných nebo nesprávně transformovaná výběrová data. Samotné testování autokorelace lze provést několika způsoby, přičemž mezi nejdůležitější patří grafické testy ACF a PACF nebo sofistikovaný test Durbin-Watson.


V rámci testování je nezbytné, aby nedocházelo především k autokorelaci 1. řádu. Případné takto vzniklé problémy se dají odstranit, anebo alespoň zmírnit pomocí dvou metod, a to Praisovou-Winstenovou metodou či Cochrane-Orcuttovou metodou, dle Hančlová [12].

ACF a PACF test

Grafické testy ACF a PACF, které lze vytvořit pomocí programu SPSS, a to následujícím způsobem: Analyze → Forecasting → Autocorrelations → Variables: Standardized Residual. Tomuto kroku však předchází vytvoření další proměnné, tentokrát ZRE_1 (standardizovaná rezidua). To lze provést následovně: Analyze → Regression → Linear → Standardized Residuals, Durbin-Watson Residuals.


Grafický test ACF představuje graf autokorelační funkce, naopak grafický test PACF představuje graf parciální autokorelační funkce. Oba tyto testy uvádí Graf 3.6 a Graf 3.7.

Graf 3.6 Test autokorelace pomocí testu ACF



Zdroj: Vlastní zpracování v SPSS

Graf 3.7 Test autokorelace pomocí testu PACF



Zdroj: Vlastní zpracování v SPSS

V rámci Grafu 3.6 je na ose x je zobrazován řád posunu, jinými slovy zpoždění, a na ose y korelace. Znázorněné linie v grafu pak představují dílčí intervaly. Na základě sloupců přesahujících tyto intervaly lze pak soudit, zda se v modelu vyskytuje autokorelace či nikoli.

Z výše uvedeného grafu je však zřejmé, že zde k této autokorelaci nedochází. S výjimkou drobného přesahu u druhého řádu se dané hodnoty pohybují v rámci konfidenčního intervalu.

V rámci Grafu 3.6 lze usuzovat sériovou závislost přímo řádu k . I zde je jednoznačně zřejmé, že ani zde se nevyskytuje parciální autokorelace.

Durbin – Watsonova statistika

Dále je přistoupeno k testování pomocí Durbin-Watsonova testu autokorelace. Tento test je založen na stanovení dvou odlišných hypotéz, přičemž slouží pro testování autokorelace 1. řádu.

Hypotézy:

H_0 : autokorelace 1. řádu není významná, tj. $\rho = 0$.

H_1 : autokorelace 1. řádu je významná (kladná nebo záporná), tj. $\rho \neq 0$.

Předpoklady:

Hodnota DW statistiky se chová podle nestandardního d -rozdělení z intervalu $<0; 4>$ a je symetrická se střední hodnotou 2.

Za předpokladu normality bílého šumu náhodné složky u_t , má d -rozdělení dvě kritické hodnoty d_L a d_U .

Rozhodující kritérium:

$DW < d_L$

$DW > 4 - d_U$

Pro tento test jsou kritické hodnoty d_L a d_U dále zjištěny pomocí tabulek uvedených na této webové stránce <http://www.stanford.edu/~clint/bench/dwcrit.htm>. Například pro $N = 47$ (počet pozorování) a $k = 3$ (počet koeficientů) jsou kritické hodnoty ve výši $d_L = 1,44352$ a $d_U = 1,62038$.


Hraniční body pro ověření autokorelace:

$$4 - dU = 2,37962$$

$$4 - dL = 2,55648$$

Samotnou hodnotu Durbin-Watsona lze získat z Tab. 3.3, kde $dvyp = 1,720$. Obecné schéma Durbin-Watsonova testu pro určení autokorelace je znázorněno na schématu 3.3.

Graf 3.8 Test autokorelace pomocí Durbin-Watsonova testu



Zdroj: Vlastní zpracování

Z daného schématu je patrné, že hodnota DW se nachází mezi hodnotami dU a $4 - dU$, z čehož vyplývá, že náleží do zóny žádné autokorelace. Z tohoto důvodu lze jednoznačně rozhodnout, že v modelu nedochází k autokorelaci 1. řádu. Na základě předešlého testu (ACF a PACF) také autokorelace nebyla potvrzena.

3.9 Statistická verifikace modelu

Statistická verifikace je zásadní pro určení významnosti a použití odhadovaného modelu. Statistická verifikace určí, na kolik je model přesný a spolehlivý. Mezi základní metody statistické verifikace lze využít např. výpočet a interpretaci koeficientu determinace a upraveného koeficientu determinace, dále také testování statistické významnosti modelu.

3.9.1 Koeficient determinace

Koeficient determinace lze vyjádřit jako poměr, ve kterém jsou změny výstupu modelu způsobeny vysvětlujícími proměnnými. Determinační koeficient, který je v rovnici označen jako R^2 , lze vyjádřit pomocí vztahu (3.31):

$$R^2 = \frac{ESS}{TSS} = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (3.31)$$

kde ESS představuje vysvětlený součet čtverců a TSS úplný součet čtverců. Koeficient determinace může nabývat hodnot v rozmezí $\langle 0, 1 \rangle$.

Za předpokladu, že je hodnota determinačního koeficientu 1, proměnné dokonale vysvětlují odhadovaný model. Pokud je hodnota R^2 rovna nule, vysvětluje celý model residuální části. Odhadovaný model pak nemá žádný smysl. Tento test nemá adekvátní odezvu na změnu počtu pozorování a ani dostatečně nezohledňuje vyšší počet vysvětlujících proměnných. Proto se používá korigovaný koeficient determinace.

3.9.2 Korigovaný koeficient determinace

V praxi se více běžně využívá korigovaný koeficient determinace. Tato statistika má stejnou interpretaci, jako R^2 a označuje se R^2_{adj} . Korekce koeficientu determinace se provádí podle vztahu (3.32),

$$R^2_{adj} = 1 - \left[\frac{n-1}{n-k} \right] \cdot (1 - R^2), \quad (3.32)$$

kde k je počet vysvětlujících proměnných plus jedna a n je počet pozorování. Korigovaný koeficient determinace může nabývat hodnot v rozmezí $\langle 0, 1 \rangle$. Dále platí, že $R^2 > R^2_{adj}$, případně pokud $R^2 = 1$, pak $R^2 = R^2_{adj}$.

3.9.3 F-test

F-test testuje nulovou hypotézu, že odhadované koeficienty v daném modelu jsou rovny nule vůči alternativě, že alespoň jeden je nenulový.

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0, \quad (3.33)$$

$$H_1: \beta_1 \neq 0 \vee \beta_2 \neq 0 \vee \dots \vee \beta_k \neq 0, \quad (3.34)$$

kde β_i představují parametry jednotlivých vysvětlujících proměnných. Testování je založeno na porovnávání statistiky F s kritickou hodnotou F_{krit} .

$$F = \frac{ESS/(k-1)}{RSS/(n-k)} = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 / (k-1)}{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 / (n-k)}, \quad (3.35)$$

$$F_{\text{krit}}: F_{1-\alpha}(df1, df2), \quad (3.36)$$

kde reziduální součet čtverců představuje RSS. Při testování je sledováno Ficherovo-Snedecorovo F-rozdělení. Tuto funkci lze sledovat na zvolené hladině spolehlivosti α . První a druhý stupeň volnosti představují parametry df_1 a df_2 . Pro parametr df_1 , že je roven výrazu $(k-1)$, pro parametr df_2 pak platí, že je roven výrazu $(n-k)$.

4 Testování kointegrace mezi vybranými akciovými indexy

V této části diplomové práce bude zkoumána v první řadě stacionarita časových řad, po které bude proveden kointegrační test mezi jednotlivými sektorovými indexy. Následně bude proveden odhad VEC modelu pro jednotlivé modely. Ze získaných hodnot statistických hodnot VEC modelu budou sestaveny kointegrační grafy závislosti mezi jednotlivými sektorovými indexy. Správnost této aplikační části bude ověřena pomocí statistické verifikace. Všechny uvedené testy budou provedeny pomocí software EViews.

4.1 Vstupní data


Data byla stažena od poskytovatele dat firmy STOXX, na webové adrese <http://www.stoxx.com>. Pro analýzu vzájemného kointegračního vztahu byly jako ukázkové vzory použity zástupci bankovního, automobilového a potravinářského sektoru. Tato data jsou rozdělena do tří částí pro přehlednější analýzu v jednotlivých časových obdobích, před krizí, během krize a po krizi.

Vzhledem ke skutečnosti, že nelze přesně určit jediný den, kdy vznikla finanční krize, jsou data rozdělena takovým způsobem, aby co nejpřesněji vystihla jednotlivé fáze před krizí, během krize a období po krizi. Období před krizí je založeno na 2081 pozorováních od 10/1/2000 po 31/12/2007. Období během krize obsahuje 518 pozorování od 8/1/2008 po 31/12/2009. Následující období po krizi je založeno na 1087 pozorováních od 8/1/2010 po 27/3/2014. Výzkum je prováděn na denních datech.

Cílem práce bude potvrdit nebo vyvrátit vzájemné kointegrační vazby. První sektor zahrnuje automobilový průmysl. Druhý sektor představuje bankovní sektor a třetí sektor zobrazuje vývoj potravinářský průmyslu. Z těchto sektorových indikátorů kapitálového trhu bude vždy pro dané období sestavena matice, aby bylo možné přehledně zachytit jednotlivé výsledky aplikovaných testů. Grafické zobrazení denních dat jednotlivých časových řad uvádějí grafy 4.1 až 4.9.

Grafy jednotlivých sektorů před krizí

Graf č. 4.1 – Index automobilového sektoru před krizí



Zdroj: Vlastní zpracování v EViews

Graf č. 4.1 zobrazuje index automobilového sektoru před krizí, je založen na 2081 pozorováních od 10/1/2000 po 31/12/2007.


Graf č. 4.2 – Index bankovního sektoru před krizí



Zdroj: Vlastní zpracování v EViews

Graf č. 4.2 zobrazuje index bankovního sektoru před krizí, je založen na 2081 pozorováních od data 10/1/2000 po 31/12/2007.

Graf č. 4.3 – Index potravinářského sektoru před krizí




Zdroj: Vlastní zpracování v EViews

Graf č. 4.3 zobrazuje index potravinářského sektoru před krizí, je založen na 2081 pozorováních od 10/1/2000 po 31/12/2007.

Grafy jednotlivých průmyslů během krize

Graf č. 4.4 – Index automobilového sektoru během krize



Zdroj: Vlastní zpracování v EViews

Graf č. 4.4 zobrazuje index automobilového sektoru během krize, je založen na 518 pozorováních od 8/1/2008 po 31/12/2009.

Graf č. 4.5 – Index bankovního sektoru během krize



Zdroj: Vlastní zpracování v EViews

Graf č. 4.5 zobrazuje index bankovního sektoru během krize, je založen na 518 pozorováních od 8/1/2008 po 31/12/2009.

Graf č. 4.6 – Index potravinářského sektoru během krize




Zdroj: Vlastní zpracování v EViews

Graf č. 4.6 zobrazuje index potravinářského sektoru během krize, je založen na 518 pozorováních od 8/1/2008 po 31/12/2009.

Grafy jednotlivých průmyslů po krizi

Graf č. 4.7 – Index automobilového sektoru po krizi



Zdroj: Vlastní zpracování v EViews

Graf č. 4.7 zobrazuje index automobilového sektoru po krizi, je založen na 1087 pozorováních od 8/1/2010 po 27/3/2014.


Graf č. 4.8 – Index bankovního sektoru po krizi



Zdroj: Vlastní zpracování v EViews

Graf č. 4.8 zobrazuje index bankovního sektoru po krizi, je založen na 1087 pozorováních od 8/1/2010 po 27/3/2014.

Graf č. 4.9 – Index potravinářského sektoru po krizi



Zdroj: Vlastní zpracování v EViews

Graf č. 4.9 zobrazuje index potravinářského sektoru po krizi, je založen na 1087 pozorováních od 8/1/2010 po 27/3/2014.

4.2 Přehled modelů

Jednotlivé časové řady byly rozděleny na tři časové úseky. V každém tomto úseku byl proveden kointegrační test ve všech kombinacích časových řad, přičemž pro lepší interpretaci výsledků byla sestavena přehledná matice a jednotlivé kombinace sektorů byly označeny jako nezávislé modely.

Tab. 4.1 Přehled předkrizových modelů

Sektory	Automobilový sektor	Bankovní sektor	Potravinářský sektor
Automobilový sektor	X		
Bankovní sektor	A1	X	
Potravinářský sektor	A2	A3	X

Zdroj: Vlastní zpracování

Tabulka 4.1 zobrazuje vzájemné kombinace jednotlivých sektorů v období před krizí od 10/1/2000 do 31/12/2007. Tyto kombinace jsou později v práci označeny jako samostatné modely pod označením A1, A2 a A3.

Tab. 4.2 Přehled modelů během krize

Sektory	Automobilový sektor	Bankovní sektor	Potravinářský sektor
Automobilový sektor	X		
Bankovní sektor	B1	X	
Potravinářský sektor	B2	B3	X

Zdroj: Vlastní zpracování

Tabulka 4.2 zobrazuje vzájemné kombinace jednotlivých sektorů v období během krize od 8/1/2008 do 31/12/2009. Veškeré kombinace jednotlivých sektorů jsou následně v práci označeny jako samostatné modely pod označením B1, B2 a B3.

Tab. 4.3 Přehled modelů po krizi

Sektory	Automobilový sektor	Bankovní sektor	Potravinářský sektor
Automobilový sektor	X		
Bankovní sektor	C1	X	
Potravinářský sektor	C2	C3	X

Zdroj: Vlastní zpracování

Tabulka 4.3 zobrazuje vzájemné kombinace jednotlivých sektorů v období po krizi od data 8/1/2010 do 27/3/2014. Veškeré kombinace jednotlivých sektorů jsou následně v práci označeny jako samostatné modely pod označením C1, C2 a C3.

4.3 Výsledky testů stacionarity

Nejdůležitějším předpokladem kointegrační analýzy je nestacionarita časových řad. V této části diplomové práce budou časové řady testovány na nestacionaritu pomocí ADF a PP testu. Testy budou provedeny na hladině významnosti 5%.

ADF – test

Jako první byl proveden rozšířený Dickey-Fuller test. Nulová hypotéza testování je stanovena podle hypotézy (3.10), alternativní hypotézu lze stanovit podle (3.11).

Hypotézy lze tedy slovně zapsat následovně:

H0: Časová řada obsahuje jednotkový kořen.

H1: Časová řada neobsahuje jednotkový kořen.

Testovou statistiku lze získat výpočtem (3.12), pro účely ověření stacionarity je však získána provedením ADF testu v softwaru EViews. Testování stacionarity bude tedy provedeno pro všechny varianty testů bez konstanty a trendu (0), s konstantou (I) a s konstantou i trendem (I+T), které jsou obsaženy v časových řadách a vyhodnoceny na hladině pravděpodobnosti 5 %. Analýza bude zaměřena převážně na varianty (I) a (I+T), neboť nejpravděpodobněji znázorňují charakter zadaných časových řad. Výsledky testování pomocí ADF testu pro všechny časové řady na hladině významnosti 5 % jsou uvedeny v tabulce 4.11.

Tab. 4.11 ADF test časových řad

ČR	Období	Varianta	p-statistika	ADF	Závěr
Automobilový průmysl	Před krizí	I	28,59%	-2,002606	H0 nelze zamítnout
		I+T	63,69%	-1,932553	H0 nelze zamítnout
	Během krize	I	13,20%	-2,437196	H0 nelze zamítnout
		I+T	60,86%	-1,983206	H0 nelze zamítnout
	Po krizi	I	72,40%	-1,084039	H0 nelze zamítnout
		I+T	67,09%	-1,866996	H0 nelze zamítnout
Bankovní průmysl	Před krizí	I	29,25%	-1,987649	H0 nelze zamítnout
		I+T	64,96%	-1,908520	H0 nelze zamítnout
	Během krize	I	22,42%	-2,152880	H0 nelze zamítnout
		I+T	66,67%	-1,873680	H0 nelze zamítnout
	Po krizi	I	72,31%	-1,086366	H0 nelze zamítnout
		I+T	69,41%	-1,821015	H0 nelze zamítnout
Potravinářský průmysl	Před krizí	I	26,29%	-2,056200	H0 nelze zamítnout
		I+T	42,17%	-2,321085	H0 nelze zamítnout
	Během krize	I	2,80%	-3,089447	H0 nelze zamítnout
		I+T	19,25%	-2,814893	H0 nelze zamítnout
	Po krizi	I	71,18%	-1,115052	H0 nelze zamítnout
		I+T	16,18%	-2,903344	H0 nelze zamítnout

Zdroj: Vlastní zpracování

Z tabulky 4.11 nelze ani v jednom případě ze všech zkoumaných proměnných zamítnout nulovou hypotézu. Na základě vyhodnocení testové statistiky, ani podle p-statistiky. Existuje tedy předpoklad, že časové řady obsahují v úrovních jednotkový kořen, a tedy jsou nestacionární.

Phillips-Peron test jednotkového kořene

Další z možných způsobů testování jednotkového kořene proběhne pomocí PP testu. Stejně jako u ADF testu je metodika testování popsána v části 3.2.2. PP test používá hypotézy odpovídající ADF testu. Tyto hypotézy lze slovně vyjádřit takto:

H0: Časová řada obsahuje jednotkový kořen.

H1: Časová řada neobsahuje jednotkový kořen.

Testová statistika bude získána pro účely ověření stacionarity PP testem v softwaru EViews.

Nulovou hypotézu lze zamítnout na základě porovnání testové a kritické hodnoty nebo díky nedostatečné významnosti (vyjádřeno p-statistikou).

Testování se provádí stejně jako u ADF testu pro všechny tři varianty testu. Testy jsou tedy provedeny s konstantou (I), bez konstanty a trendu (0), a s konstantou i trendem (I+T), které jsou obsaženy v časových řadách. Tyto testy jsou vyhodnoceny na hladině významnosti 5 %. Výsledky testování jsou uvedeny v tabulce Tab. 4.12. Stejně jako u testování ADF je kladen důraz na druhou a třetí variantu testu. Testové a kritické statistiky všech variant obsahuje příloha 4 a 5.

Tab. 4.12 PP test časových řad

ČR	Období	Varianta	p-statistika	PP	Závěr
Automobilový průmysl	Před krizí	I	28,36%	-2,007882	H0 nelze zamítnout
		I+T	62,77%	-1,949699	H0 nelze zamítnout
	Během krize	I	13,50%	-2,426144	H0 nelze zamítnout
		I+T	60,86%	-1,983206	H0 nelze zamítnout
	Po krizi	I	71,95%	-1,095655	H0 nelze zamítnout
		I+T	65,54%	-1,896942	H0 nelze zamítnout
Bankovní průmysl	Před krizí	I	35,45%	-1,853912	H0 nelze zamítnout
		I+T	72,28%	-1,762151	H0 nelze zamítnout
	Během krize	I	23,90%	-2,114846	H0 nelze zamítnout
		I+T	73,18%	-1,740597	H0 nelze zamítnout
	Po krizi	I	73,35%	-1,059178	H0 nelze zamítnout
		I+T	72,53%	-3,413937	H0 nelze zamítnout
Potravinářský průmysl	Před krizí	I	29,79%	-1,975534	H0 nelze zamítnout
		I+T	48,84%	-2,200655	H0 nelze zamítnout
	Během krize	I	4,43%	-2,914940	H0 nelze zamítnout
		I+T	29,43%	-2,570194	H0 nelze zamítnout
	Po krizi	I	70,92%	-1,121562	H0 nelze zamítnout
		I+T	15,14%	-2,936059	H0 nelze zamítnout

Zdroj: Vlastní zpracování

Z tabulky 4.12 je zřejmé, že ani v jednom případě nelze zamítnout nulovou hypotézu, ani na základě porovnání testové statistiky, ani podle p-statistiky. Lze předpokládat, že časové řady obsahují jednotkový kořen a jsou tedy nestacionární.

Vyhodnocení testování stacionarity

Vyhodnocení testování stacionarity časových řad jsou uvedena v souhrnné tabulce 4.13. Byly provedeny testy jednotkového kořene ADF a PP a vyhodnoceny na hladině významnosti 5 %, pro varianty testování s konstantou (I) a s konstantou i trendem (I+T), které jsou obsaženy v časových řadách.

Testy ukázaly, že jsou nestacionární. Nicméně se v rámci diplomové práce zaměřujeme na časové řady typu $I(1)$, tedy takové, které jsou po provedení první difference stacionární. Tedy

$$\Delta y_t = y_t - y_{t-1},$$

bude řada stacionární.

Tab. 4.12 Vyhodnocení testování stacionarity časových řad po první diferenci

ČR	Období	ADF	PP	Hodnocení
Automobilový průmysl	Před krizí	Stacionární	Stacionární	Stacionární
	Během krize	Stacionární	Stacionární	Stacionární
	Po krizi	Stacionární	Stacionární	Stacionární
Bankovní průmysl	Před krizí	Stacionární	Stacionární	Stacionární
	Během krize	Stacionární	Stacionární	Stacionární
	Po krizi	Stacionární	Stacionární	Stacionární
Potravinařský průmysl	Před krizí	Stacionární	Stacionární	Stacionární
	Během krize	Stacionární	Stacionární	Stacionární
	Po krizi	Stacionární	Stacionární	Stacionární

Zdroj: Vlastní zpracování

Z tabulky 4.12 vyplývá, že všechny časové řady jsou stacionární po první diferenci. A jsou tedy řádu - $I(1)$, pro všechny zohledněné varianty testování ADF i PP testy na hladině významnosti 5%. Kritické, testovací a p-statistiky jsou uvedeny v přílohách 5.

Tab. 4.13 Vyhodnocení testování stacionarity časových řad

ČR	Období	ADF	PP	Hodnocení	Řád integrace
Automobilový průmysl	Před krizí	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Během krize	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Po krizi	Nestacionární	Nestacionární	Nestacionární	$I(1)$
Bankovní průmysl	Před krizí	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Během krize	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Po krizi	Nestacionární	Nestacionární	Nestacionární	$I(1)$
Potravinářský průmysl	Před krizí	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Během krize	Nestacionární	Nestacionární	Nestacionární	$I(1)$
	Po krizi	Nestacionární	Nestacionární	Nestacionární	$I(1)$

Zdroj: Vlastní zpracování

Z tabulky 4.13 vyplývá, že všechny časové řady jsou nestacionární v úrovních a integrované stejného řádu - $I(1)$, pro všechny zohledněné varianty testování ADF i PP testy na hladině významnosti 5%. Kritické, testovací a p-statistiky jsou uvedeny v příloze 4.

Další kapitola bude věnována odhadu kointegračních vztahů pro jednotlivé modely.

4.4 Testování kointegrace

V části 4.4 jsou provedeny testy kointegrace. Kointegrace představuje dlouhodobý rovnovážný stav mezi proměnnými, jenž vzniká kombinací nestacionárních proměnných. Teoretická část je uvedena v kapitole 3.5.

Pro testování dlouhodobého rovnovážného stavu byl použit Johansenův test kointegrace. Tento test je založen na vyhledávání r počtu kointegračních rovnic. Pokud bude nalezena alespoň jedna r kointegrační rovnice, tak v modelu existuje alespoň jeden kointegrační vztah. Tento vztah lze obecně zapsat dle rovnice (3.26).

Při testování kointegrace pomocí Johansenova testu jsou použity dva způsoby výpočtu testové statistiky. Testová statistika může být vypočtena pomocí Trace testu a Maximum Eigenvalue testu. Výpočet Trace statistiky je prováděn pomocí rovnice (3.28) a výpočet Maximum Eigenvalue test podle rovnice (3.29). Obě vypočtené statistiky jsou následně porovnány s kritickými hodnotami. Johansenovy testy kointegrace jsou provedeny pomocí výpočetního programu Eviews. Pomocí tohoto programu jsou také vypočteny p -statistiky a vyhodnocen počet kointegračních rovnic v modelu.

Výsledky testů kointegrace jsou prezentovány rozdělené do tří částí. První část modelů je testována na základě dat z období před krizí a výsledky jsou zobrazeny v tabulkách 4.18 až 4.24. Následuje testování kointegrace během krize, výsledky jsou zobrazeny v tabulkách 4.18 až 4.24, výsledky po krizi budou zobrazeny v tabulkách 4.18 až 4.24.

4.4.1 Před krizí

V této podkapitole budou uvedeny výsledky jednotlivých kointegračních testů, které zahrnují Trace test a Maximum Eigenvalue test.

Tab. 4.18 - Trace test A1

Model A1		
Počet koint. rovnic	0	1
Vlastní číslo	0,003550	0,001631
Testová statistika	10,79762	3,396668
Kritická hodnota	15,49471	3,841466
p-statistika	0,224200	0,065300

Zdroj: Vlastní zpracování

Tab. 4.19 – Maximum Eigenvalue test A1

Model A1		
Počet koint. rovnic	0	1
Vlastní číslo	0,003550	0,001631
Testová statistika	7,400956	3,396668
Kritická hodnota	14,26460	3,841466
p-statistika	0,442900	0,065300

Z tabulky 4.18 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu A1. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.19, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.20 - Trace test A2

Model A2		
Počet koint. rovnic	0	1
Vlastní číslo	0,005251	0,003260
Testová statistika	14,75060	6,794895
Kritická hodnota	15,49471	3,841466
p-statistika	0,022500	0,009100

Zdroj: Vlastní zpracování

Tab. 4.21 – Maximum Eigenvalue test A2

Model A2		
Počet koint. rovnic	0	1
Vlastní číslo	0,005251	0,003260
Testová statistika	10,95571	6,794895
Kritická hodnota	14,26460	3,841466
p-statistika	0,156400	0,009100

Z tabulky 4.20 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu A2. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.21, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.22 - Trace test A3

Model A3		
Počet koint. rovnic	0	1
Vlastní číslo	0,002950	0,002514
Testová statistika	11,38558	5,237530
Kritická hodnota	15,49471	3,841466
p-statistika	0,188900	0,022100

Zdroj: Vlastní zpracování

Tab. 4.23 – Maximum Eigenvalue test A3

Model A3		
Počet koint. rovnic	0	1
Vlastní číslo	0,002950	0,002514
Testová statistika	6,148048	5,237530
Kritická hodnota	14,26460	3,841466
p-statistika	0,5943	0,022100

Z tabulky 4.22 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu A3. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.23, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Analýza byla provedena na 2084 pozorováních. Jak vyplývá z tabulek 4.18, 4.20 a 4.22, Trace test prokázal, že modely A1, A2 a model A3 neobsahují ani jeden kointegrační vztah a jsou dlouhodobě na sobě nezávislé, neboť $F_{\text{krit.}} > F_{\text{test}}$. Výsledky Trace testu by měly být potvrzeny Maximum Eigenvalue testem.

Z tabulek 4.19, 4.21 a 4.23 ukazují výsledky Maximum Eigenvalue testu, který stejně jako Trace test neprokázal žádný kointegrační vztah, neboť $F_{\text{krit.}} > F_{\text{test}}$.

Lze tedy konstatovat, že na hladině významnosti 5 %, pro test č. 2 Johansenova kointegračního testu, obě varianty, jak Trace test, tak Maximum Eigenvalue test, neprokázaly žádný dlouhodobý rovnovážný vztah ani v jednom z modelů A1, A2 a A3.

4.4.2 Během krize

V této podkapitole budou uvedeny výsledky jednotlivých kointegračních testů, které zahrnují Trace test a Maximum Eigenvalue test v jednotlivých modelech B1, B2 a B3 během krizového období.

Tab. 4.24 - Trace test B1

Model B1		
Počet koint. rovnic	0	1
Vlastní číslo	0,018245	0,009893
Testová statistika	14,68827	5,150147
Kritická hodnota	25,87211	12,51798
p-statistika	0,600500	0,574900

Zdroj: Vlastní zpracování

Z tabulky 4.24 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu B1. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.25, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.25 – Maximum Eigenvalue test B1

Model B1		
Počet koint. rovnic	0	1
Vlastní číslo	0,018245	0,009893
Testová statistika	9,538120	5,150147
Kritická hodnota	19,38704	12,51798
p-statistika	0,668100	0,574900

Tab. 4.26 - Trace test B2

Model B2		
Počet koint. rovnic	0	1
Vlastní číslo	0,022684	0,008564
Testová statistika	14,34066	4,455162
Kritická hodnota	15,49471	3,841466
p-statistika	0,0372	0,034800

Zdroj: Vlastní zpracování

Z tabulky 4.26 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu B2. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.27, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.27 – Maximum Eigenvalue test B2

Model B2		
Počet koint. rovnic	0	1
Vlastní číslo	0,022684	0,008564
Testová statistika	11,88549	4,455162
Kritická hodnota	14,26460	3,841466
p-statistika	0,1150	0,034800

Tab. 4.28 - Trace test B3

Model B3		
Počet koint. rovnic	0	1
Vlastní číslo	0,020951	0,005513
Testová statistika	13,83146	2,863611
Kritická hodnota	15,49471	3,841466
p-statistika	0,087700	0,090600

Zdroj: Vlastní zpracování

Tab. 4.29 – Maximum Eigenvalue test B3

Model B3		
Počet koint. rovnic	0	1
Vlastní číslo	0,020951	0,005513
Testová statistika	10,96785	2,863611
Kritická hodnota	14,26460	3,841466
p-statistika	0,155800	0,090600

Z tabulky 4.28 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu B3. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.29, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Analýza byla provedena na 518 pozorováních. Jak vyplývá z tabulek 4.18,21,23. Trace test prokázal, že modely B1, B2 a B3 neobsahují ani jeden kointegrační vztah a jsou dlouhodobě na sobě nezávislé, neboť $F \text{ krit.} > F \text{ test}$. Výsledky Trace testu by měly být potvrzeny Maximum Eigenvalue testem.

Z tabulek 4.20, 4.22, 4.24 ukazují výsledky Maximum Eigenvalue testu, který stejně jako Trace test neprokázal žádný kointegrační vztah, neboť $F \text{ krit.} > F \text{ test}$.

Lze tedy konstatovat, že na hladině významnosti 5 %, pro test č. 2 Johansenova kointegračního testu, obě varianty, jak Trace test, tak Maximum Eigenvalue test, neprokázaly žádný dlouhodobý rovnovážný vztah ani v jednom z modelů B1, B2 a B3.

4.4.3 Po krizi

Analýza byla provedena celkem na 1087 pozorováních mezi jednotlivými sektory v období po krizi, jež zahrnuje období od 8/1/2010 do 27/3/2014.

Tab. 4.30 - Trace test C1

Model C1		
Počet koint. rovnic	0	1
Vlastní číslo	0,004648	0,000720
Testová statistika	5,847086	0,782463
Kritická hodnota	15,49471	3,841466
p-statistika	0,713500	0,376400

Zdroj: Vlastní zpracování

Tab. 4.31 – Maximum Eigenvalue test C1

Model C1		
Počet koint. rovnic	0	1
Vlastní číslo	0,004648	0,000720
Testová statistika	5,064623	0,782463
Kritická hodnota	14,26460	3,841466
p-statistika	0,733600	0,376400

Z tabulky 4.30 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu C1. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.31, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.32 - Trace test C2

Model C2		
Počet koint. rovnic	0	1
Vlastní číslo	0,003514	0,001600
Testová statistika	5,566480	1,740234
Kritická hodnota	15,49471	3,841466
p-statistika	0,746100	0,181700

Zdroj: Vlastní zpracování

Tab. 4.33 – Maximum Eigenvalue test C2

Model C2		
Počet koint. rovnic	0	1
Vlastní číslo	0,003514	0,001600
Testová statistika	3,826246	1,740234
Kritická hodnota	14,26460	3,841466
p-statistika	0,877200	0,187100

Z tabulky 4.32 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu C2. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.33, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Tab. 4.34 - Trace test C3

Model C3		
Počet koint. rovnic	0	1
Vlastní číslo	0,003464	0,001749
Testová statistika	5,674753	1,902626
Kritická hodnota	15,49471	3,841466
p-statistika	0,7336	0,167800

Zdroj: Vlastní zpracování

Tab. 4.35 – Maximum Eigenvalue test C3

Model C3		
Počet koint. rovnic	0	1
Vlastní číslo	0,003464	0,001749
Testová statistika	3,772127	1,902626
Kritická hodnota	14,26460	3,841466
p-statistika	0,882600	0,167800

Z tabulky 4.34 je zřejmé, že Trace test neprokázal žádný kointegrační vztah v modelu C3. Znamená to, že se jednotlivé proměnné nedostanou dlouhodobě do rovnovážného stavu. Jak uvádí tabulka 4.35, tak tuto premisu potvrzuje na hladině významnosti i Maximum Eigenvalue test.

Jak vyplývá z tabulek 4.30 až 4.35. Trace test prokázal, že modely C1, C2 a C3 neobsahují ani jeden kointegrační vztah a jsou dlouhodobě na sobě nezávislé, neboť $F_{krit.} > F_{test}$. Výsledky Trace testu by měly být potvrzeny Maximum Eigenvalue Testem.

Z tabulek 4.30 až 4.35 ukazují výsledky Maximum Eigenvalue testu, který stejně jako Trace test neprokázal žádný kointegrační vztah, neboť $F_{krit.} > F_{test}$.

Lze tedy konstatovat, že na hladině významnosti 5 %, pro test č. 2 Johansenova kointegračního testu, obě varianty, jak Trace test, tak Maximum Eigenvalue test, neprokázaly žádný dlouhodobý rovnovážný vztah ani v jednom z modelů C1, C2 a C3.

4.5 Odhad VEC modelů

V předchozí části práce nebyl nalezen ani jeden kointegrační vztah. Aby bylo možné potvrdit výsledky předchozích testů, tak v diplomové práci byly vypracovány odhady vektorového modelu chyb. Tato část diplomové práce obsahuje odhad koeficientů adjustace α , členů kointegračního vektoru β . Specifikace vyhodnocení zůstávají stejné jako u testů kointegrace.

Modely nepředpokládají žádné zpoždění, neboť v diplomové práci nejde o co nejlepší sestavení výsledného modelu, ale zejména o empirické zjištění vzájemného vztahu mezi jednotlivými zkoumanými sektory.

Výstupy odhadu VECM modelu z výpočetního programu Eviews jsou uvedeny v příloze č. 5. Odhady členů kointegračních vektorů, které představují vztah dlouhodobé rovnováhy v modelech A1-C1 a jsou uvedeny v tabulkách 4.1-4.15.

4.5.1 Před krizí

Odhady členů kointegračního vektoru, který představuje předpokládaný vztah dlouhodobé rovnováhy v modelech A1, A2, A3 mezi jednotlivými vysvětlovanými proměnnými jsou uvedeny v tabulkách 4.1, 4.2, 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9.

Tab. 4.1 Odhad koint. vektoru (A1)

Proměnná	Bankovní sektor	Automobilový sektor	C
β	1	-0,3765	-53,885
Sm. odchylka	-	0,0855	-
t-statistika	-	-4,3998	-

Zdroj: Vlastní zpracování

Tab. 4.2 Odhad parametrů α a δ (A1)

Proměnná	α	Bankovní sektor	Automobilový sektor	C
Parametr	-0,005	0,0416	-0,0361	-0,006
Sm. Odchylka	0,0031	0,0263	0,01259	0,0411
t-statistika	-1,544	1,5766	-2,8652	-0,159

Model korekce chyb A1, lze zapsat pomocí vztahu (4.5) následovně:

$$QE(A1) = banks - 0,38 \cdot automobile - 53,89 \quad (4.1)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; -0,38; -53,89]$. Z rovnice lze vyčíst, že mezi bankovním a automobilovým sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.2. Z tabulky vyplývá, že

hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází pomalu.

Tab. 4.3 Odhad koint. vektoru (A2)

Proměnná	Automobilový sektor	Potravinářský sektor	C
β	1	-2,2999	197,089
Sm. odchylka	-	0,5830	-
t-statistika	-	-3,9449	-

Zdroj: Vlastní zpracování

Tab. 4. 4 Odhad parametrů α a δ (A2)

Proměnná	α	Automobilový sektor	Potravinářský sektor	C
Parametr	-0,001	-0,0243	0,1605	-0,040
Sm. Odchylka	0,002	0,0234	0,0419	0,087
t-statistika	0,609	-1,0374	3,8254	-0,417

Model korekce chyb A2, lze zapsat pomocí vztahu (4.6) následovně:

$$QE(A2) = automobile - 2,30 \cdot food + 197,09 \quad (4.2)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; -2,30; 197,09]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.4. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

Tab. 4.5 Odhad koint. vektoru (A3)

Proměnná	Bankovní sektor	Potravinářský sektor	C
β	1	1,8806	-560,85
Sm. odchylka	-	0,9953	-
t-statistika	-	1,8894	-

Tab. 4.6 Odhad parametrů α a δ (A3)

Proměnná	α	Bankovní sektor	Potravinářský sektor	C
Parametr	-0,002	0,0073	-0,0148	-0,006
Sm. Odchylka	0,0007	0,0271	0,0233	0,0412
t-statistika	-2,419	0,2696	-0,6358	-0,137

Zdroj: Vlastní zpracování

Model korekce chyb A3, lze zapsat pomocí vztahu (4.7) následovně:

$$QE(A3) = banks + 1,88 \cdot food - 560,85 \quad (4.3)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; 1,88; -560,85]$. Z rovnice jde vyčíst, že mezi bankovním a potravinářským sektorem se vyskytuje pozitivní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.6. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

4.5.2 Během krize

Model korekce chyb B1, lze zapsat pomocí vztahu (4.8) následovně:

$$QE(A3) = automobile - 1,35 \cdot banks - 77,14 \quad (4.4)$$

Tab. 4.7 Odhad koint. vektoru (B1)

Tab. 4. 8 Odhad parametrů α a δ (B1)

Proměnná	Automobilový sektor	Bankovní sektor	C	Proměnná	α	Automobilový sektor	Bankovní sektor	C
β	1	-1,3451	-77,140	Parametr	-0,02	-0,1643	0,5863	-0,045
Sm. odchylka	-	0,3065	-	Sm. Odchylka	0,012	0,0482	0,0818	0,189
t-statistika	-	-4,3883	-	t-statistika	-1,02	-3,4094	7,1599	-0,236

Zdroj: Vlastní zpracování

Vektor dlouhodobého vztahu má tento tvar $B=[1; -1,35; -77,14]$. Z rovnice jde vyčíst, že mezi automobilovým a bankovním sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.8. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

Tab. 4.9 Odhad koint. vektoru (B2)

Tab. 4. 10 Odhad parametrů α a δ (B2)

Proměnná	Automobilový sektor	Potravinářský sektor	C
β	1	-5,4119	816,99
Sm. odchylka	-	1,1372	-
t-statistika	-	-4,7588	-

Proměnná	α	Automobilový sektor	Potravinářský sektor	C
Parametr	0,007	-0,1368	0,5353	-0,092
Sm. Odchylka	0,0046	0,0458	0,0799	0,1908
t-statistika	1,5541	-2,9847	6,6931	-0,485

Zdroj: Vlastní zpracování

Model korekce chyb B2, lze zapsat pomocí vztahu (4.9) následovně:

$$QE(B2) = automobile - 5,41 \cdot food + 816,99 \quad (4.5)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; -5,41; 816,99]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.11. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

Tab. 4.11 Odhad koint. vektoru (B3)

Proměnná	Potravinářský sektor	Bankovní sektor	C
β	1	-0,3174	-158,72
Sm. odchylka	-	0,0937	-
t-statistika	-	-3,3885	-

Tab. 4. 12 Odhad parametrů α a δ (B3)

Proměnná	α	Potravinářský sektor	Bankovní sektor	C
Parametr	-0,055	0,0054	-0,1640	-0,041
Sm. Odchylka	0,0164	0,0544	0,0536	0,1094
t-statistika	-3,362	0,0993	-3,0603	-0,372

Zdroj: Vlastní zpracování

Model korekce chyb B3, lze zapsat pomocí vztahu (4.9) následovně:

$$QE(B3) = food - 0,32 \cdot banks - 158,72 \quad (4.6)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; 0,32; -158,72]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.12. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

4.5.3 Po krizi

Tab. 4.13 Odhad koint. vektoru (C1)

Proměnná	Automobilový sektor	Bankovní sektor	C
β	1	3,6424	98,418
Sm. odchylka	-	0,6545	-
t-statistika	-	-5,5653	-

Tab. 4. 14 Odhad parametrů α a δ (C1)

Proměnná	α	Automobilový sektor	Bankovní sektor	C
Parametr	-0,007	-0,1671	1,0069	0,0818
Sm. Odchylka	0,0049	0,0355	0,1165	0,0994
t-statistika	-1,503	-4,7057	-8,6414	0,8236

Zdroj: Vlastní zpracování

Model korekce chyb C1, lze zapsat pomocí vztahu (4.10) následovně:

$$QE(C1) = automobile + 3,64 \cdot banks + 98,42 \quad (4.7)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; 3,64; 98,42]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje pozitivní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.14. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

Tab. 4.15 Odhad koint. vektoru (C2)

Proměnná	Automobilový sektor	Potravinářský sektor	C
β	1	-1,4172	87,495
Sm. odchylka	-	0,4221	-
t-statistika	-	-3,3576	-

Tab. 4. 16 Odhad parametrů α a δ (C2)

Proměnná	α	Automobilový sektor	Potravinářský sektor	C
Parametr	-0,007	-0,0763	-0,3455	0,0743
Sm. Odchylka	0,0035	0,0341	0,0601	0,1017
t-statistika	-2,006	-2,2417	5,7261	0,7302

Zdroj: Vlastní zpracování

Model korekce chyb C2, lze zapsat pomocí vztahu (4.11) následovně:

$$QE(C2) = automobile - 1,42 \cdot food + 87,50 \quad (4.8)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; -1,42; 87,50]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.14. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.

Tab. 4.17 Odhad koint. vektoru (C3)

Tab. 4. 18 Odhad parametrů α a δ (C3)

Proměnná	Bankovní sektor	Potravinářský sektor	C	Proměnná	α	Bankovní sektor	Potravinářský sektor	C
β	1	-0,3768	-6,168	Parametr	-0,006	0,1031	-0,0026	0,028
Sm. odchylka	-	0,1357	-	Sm. Odchylka	0,0036	0,0395	0,0209	0,031
t-statistika	-	-6,1685	-	t-statistika	-1,8055	-1,8055	-0,1409	0,918

Zdroj: Vlastní zpracování

Model korekce chyb C3, lze zapsat pomocí vztahu (4.12) následovně:

$$QE(C3) = banks - 0,38 \cdot food - 6,17 \quad (4.9)$$

Vektor dlouhodobého vztahu má tento tvar $B=[1; -0,38; -6,17]$. Z rovnice jde vyčíst, že mezi automobilovým a potravinářským sektorem se vyskytuje negativní vztah. Odhad koeficientu dynamiky adjustace a koeficientů korekce chyb je uveden v tabulce 4.14. Z tabulky vyplývá, že hodnota α je poměrně nízká a k návratu do odhadovaného rovnovážného stavu dochází velice pomalu.


4.6 Zobrazení kointegračních závislostí

V této podkapitole bude vykreslen kointegrační vztah mezi jednotlivými sektorovými indexy. Podobně jako v předchozí kapitole budou tyto kointegrační vztahy rozděleny do jednotlivých období dle provedených analýz.

4.6.1 Před krizí

Období před krizí zahrnuje jednotlivé vztahy v modelech A1, A2 a A3.


Graf 4.6 Kointegrační vztah v modelu A1



Z grafu 4.6 je zřejmé, že kointegrační vztah v modelu A1 není ideálně stacionární, protože hodnoty v grafu pravidelně neoscilují kolem nulové hodnoty. Tento model A1 bude dále statisticky verifikován pomocí determinačního koeficientu a F-testu statistické významnosti modelu.

Zdroj: Vlastní zpracování v EViews


Graf 4.7 Kointegrační vztah v modelu A2



Grafu 4.7 představuje kointegrační vztah v modelu A2. Tento graf není ideálně stacionární. Při odhadu modelu mohlo dojít také ke statistickým nebo ekonometrickým chybám, které zhoršily jeho vypovídající schopnost.

Zdroj: Vlastní zpracování v EViews

Graf 4.8 Kointegrační vztah v modelu A3




Z grafu 4.8 je zřejmé, že kointegrační vztah v modelu A3 není stacionární. Při daném počtu pozorování by dané hodnoty neměly přesahovat interval mezi hodnotou -2 a 2. Avšak výsledné hodnoty dosahují rozmezí intervalu mezi -150 a +150.

Zdroj: Vlastní zpracování v EViews

4.6.2 Během krize

Období během krize zahrnuje jednotlivé vztahy v modelech B1, B2 a B3.


Graf 4.9 Kointegrační vztah v modelu B1



Graf 4.9 představuje kointegrační vztah modelu B1. Tento graf se nejvíce přibližuje definici stacionarity, ale tento graf také není stacionární. Z tohoto důvodu by také měl být tento model statistickou verifikací potvrzen za špatně specifikovaný.

Zdroj: Vlastní zpracování v EViews


Graf 4.10 Kointegrační vztah v modelu B2



Zdroj: Vlastní zpracování v EViews

Z grafu 4.10 je zřejmé, že kointegrační vztah v modelu B2 není ideálně stacionární. Při odhadu mohlo dojít také ke statistickým nebo ekonometrickým chybám, které zhoršily jeho vypovídající schopnost. Model je dále statisticky verifikován pomocí determinačního koeficientu a F-testu statistické významnosti modelu.

Graf 4.11 Kointegrační vztah v modelu B3




Zdroj: Vlastní zpracování v EViews

Graf 4.11 vyjadřuje kointegrační vztah v modelu B3. Ani v modelu B3 není kointegrační vztah stacionaritou potvrzen. Toto tvrzení podporuje zkoumanou tezi, že mezi sektorovými indexy neexistuje dlouhodobý vztah.

4.6.3 Po krizi

Období po krizi zahrnuje jednotlivé vztahy v modelech C1, C2 a C3.


Graf 4.12 Kointegrační vztah v modelu C1



Zdroj: Vlastní zpracování v EViews

Graf 4.12 vyjadřuje kointegrační vztah v modelu C1. V modelu C1 není kointegrační vztah stacionaritou časové řady potvrzen. Tedy mezi automobilovým a bankovním sektorem neexistuje dlouhodobý rovnovážný vztah.


Graf 4.13 Kointegrační vztah v modelu C2



Zdroj: Vlastní zpracování v EViews

Graf 4.13 popisuje kointegrační vztah mezi automobilovým a potravinářským sektorem. Tento graf není stacionární. Z tohoto důvodu neexistuje dlouhodobý rovnovážný vztah v modelu C2.

Graf 4.14 Kointegrační vztah v modelu C3



Z grafu 4.14 je zřejmé, že kointegrační vztah v modelu C3 není ideálně stacionární. Kointegrační vztah mezi bankovním a potravinářským sektorem tímto způsobem není potvrzen. Z tohoto důvodu dále bude provedena statistická verifikace všech modelů.

Zdroj: Vlastní zpracování v EViews

Na základě předchozí analýzy vyplývá, že všechny vykreslené kointegrační vztahy v modelech A1 až C3 nejsou stacionární. Z tohoto důvodu lze předpokládat, že mezi jednotlivými sektory v jakémkoli období nelze předpokládat žádný dlouhodobý rovnovážný vztah. Z tohoto důvodu bude dále provedena statistická verifikace všech modelů pomocí F-testu a koeficientu determinace.

4.7 Statistická verifikace modelů

Na základě Johansenových testů kointegrace lze konstatovat, že nebyl prokázán žádný předpoklad o existenci dlouhodobé rovnováhy mezi proměnnými. Přesto byl v předchozí kapitole sestaven model korekce chyb. Následující kapitola bude popisovat statistické ověření významnosti jednotlivých modelů. Teorie výpočtů determinačního koeficientu a stanovení F-testu významnosti modelu jsou popsány v části 3.8.

Koeficient determinace

Model je možné zhodnotit pomocí koeficientu determinace a pomocí upraveného koeficientu determinace, jejichž výpočet lze získat pomocí vztahů (3.30) a (3.31), v tomto pořadí. Koeficienty determinace byly získány při odhadu modelu VECM v programu EViews. Následující tabulka 4.1 uvádí hodnoty těchto ukazatelů pro jednotlivé modely.

Tab.: 4.1 Koeficient determinace

Model A1	
Determinační koeficient	0,005862
Upravený determinační koeficient	0,003469
Model A2	
Determinační koeficient	0,008771
Upravený determinační koeficient	0,006384
Model A3	
Determinační koeficient	0,003400
Upravený determinační koeficient	0,001001
Model B1	
Determinační koeficient	0,097614
Upravený determinační koeficient	0,088836
Model B2	
Determinační koeficient	0,085845
Upravený determinační koeficient	0,076952
Model B3	
Determinační koeficient	0,054702
Upravený determinační koeficient	0,045506
Model C1	
Determinační koeficient	0,076453
Upravený determinační koeficient	0,072189
Model C2	
Determinační koeficient	0,035545
Upravený determinační koeficient	0,031092
Model C3	
Determinační koeficient	0,016155
Upravený determinační koeficient	0,011613

Zdroj: Vlastní zpracování

V modelu A1 dosahuje koeficient determinace hodnoty 0,005862. Toto číslo vyjádříme v procentech a výsledná hodnota je 0,59 %. Jednotlivé proměnné se tedy v modelu ovlivňují pouze z 0,59%. Upravený koeficient determinace dosahuje ještě nižší hodnoty 0,35 %. Na základě získaných statistik lze konstatovat, že model A1 je statisticky nevýznamný.

V model A2 dosahuje koeficient determinace hodnoty 0,88%. Automobilový a potravinářský sektor se tedy vzájemně ovlivňuje pouze ve výši 0,88%. Dle upraveného determinačního koeficientu se jednotlivé sektory v modelu A2 ovlivňují pouze ve výši 0,64 %. Na základě získaných statistik lze konstatovat, že model A2 je statisticky nevýznamný.

Model A3 vyjadřuje vztah mezi bankovním a potravinářským průmyslem v hodnotě 0,34 %. Pomocí upraveného determinačního koeficientu se sektory vzájemně ovlivňují ve výši 0,10 %. Ze získaných statistik v modelu A3 jednoznačně neexistuje dlouhodobý rovnovážný vztah.

Jednotlivý vztah mezi automobilovým a bankovním sektorem během krize vyjadřuje model B1 ve výši 9,76 %. Dle upraveného koeficientu determinace je vztah mezi proměnnými ve výši 8,88 %. Během krize je souvislost daleko vyšší, než v předchozím období, i přesto je model nutné zamítnout z důvodu nízké vypovídací hodnoty.

Vztah mezi automobilovým a potravinářským průmyslem vyjádřený koeficientem determinace je Model B2 8,58 %. Vyjádřeno upraveným koeficientem determinace je závislost nižší, pouze 7,70 %. Tato statistická závislost je malá, proto v modelu B2 také neexistuje dlouhodobý rovnovážný vztah.

Dlouhodobý rovnovážný vztah mezi bankovním a potravinářským sektorem je vyjádřen ve výši 5,5 %. Dle upraveného koeficientu determinace je vztah na úrovni 4,6 %. Jednotlivé proměnné se tedy jen málo ovlivňují. Z tohoto důvodu je model B3 statisticky nevýznamný.

Vztah mezi automobilovým a bankovním sektorem v modelu C1 je vysvětlován na úrovni 7,6 %. Pomocí upraveného koeficientu determinace je vztah vysvětlován ze 7,2 %. Na základě získaných statistik lze konstatovat, že model C1 má také nízkou vypovídací schopnost.

Model C2 popisuje vztah mezi automobilovým a potravinářským průmyslem. Tyto dva sektory se ovlivňují v dlouhodobém rovnovážném vztahu ve výši 3,5 %. Podle

upraveného koeficientu determinace se sektory ovlivňují v 3,1 %. Z důvodu nízkého statistické závislosti je model zamítnut.

Model C3 vyjadřuje vztah mezi bankovním a potravinářským sektorem na úrovni 1,6 %. Dle upraveného koeficientu determinace 1,16 %. Na základě získaných statistik lze konstatovat, že model C3 má nízkou vypovídací schopnost.

Z tabulky 4.7 vyplývá, že u všech modelů dosahují koeficienty determinace srovnatelných hodnot, pouze během krize se zvyšuje závislost mezi jednotlivými sektory. Ovšem ve všech případech lze ze získaných statistik z důvodu nízkých hodnot zamítnout dlouhodobé rovnovážné vztahy mezi jednotlivými indexy.

F-test

F-test má za úkol prověřit statistickou významnost celého modelu. Testování bude provedeno pro jednotlivé modely na hladině pravděpodobnosti 5 %, stejně jako všechna předchozí zkoumání. Pro realizaci F-testu musí být nejprve stanoveny hypotézy, které budou prokazovány. Tyto hypotézy lze slovně uvést podle vztahů (3.33) a (3.34) následovně:

H_0 : Model není statisticky významný.

H_1 : Model je statisticky významný.

Aby bylo možno testovaný model přijmout jako statisticky významný, musí být zamítnuta nulová hypotéza. Nulová hypotéza je zamítnuta, pokud je testovací statistika větší než vypočtená kritická hodnota. Testová statistika je získána pomocí softwaru Eviews. Tento výpočet v softwaru je proveden pomocí vzorce (3.35).

Hodnotu kritické statistiky lze matematicky popsat vztahem (3.36). Také jako u testové statistiky budou využity výsledky výpočetního programu Eviews. Hodnoty testovacích a kritických hodnot všech modelů jsou uvedeny v tabulce 4.2.

Tab. 4.2 Testovací a kritické hodnoty F-testu

Model A1	
Testovací statistika (F)	2,449549
Upravený determinační koeficient (F_{krit})	3,845936
Model A2	
Testovací statistika (F)	3,675525
Upravený determinační koeficient (F_{krit})	3,845936
Model A3	
Testovací statistika (F)	1,417135
Upravený determinační koeficient (F_{krit})	3,845936
Model B1	
Testovací statistika (F)	1,12026
Upravený determinační koeficient (F_{krit})	3,859543
Model B2	
Testovací statistika (F)	2,653519
Upravený determinační koeficient (F_{krit})	3,859543
Model B3	
Testovací statistika (F)	2,948734
Upravený determinační koeficient (F_{krit})	3,859543
Model C1	
Testovací statistika (F)	1,93057
Upravený determinační koeficient (F_{krit})	3,850044
Model C2	
Testovací statistika (F)	2,982735
Upravený determinační koeficient (F_{krit})	3,850044
Model C3	
Testovací statistika (F)	3,556626
Upravený determinační koeficient (F_{krit})	3,850044

Zdroj: Vlastní zpracování

Na základě porovnání testovací a kritické statistiky modelu A1 na hladině významnosti 5 %, při 2081 pozorováních lze konstatovat, že tento model je statisticky nevýznamný. V tomto případě platí, že $F < F_{krit}$, tudíž lze přijmout nulovou hypotézu. Model není statisticky významný.

Pomocí statistického F-testu v modelu A2 je nutné ze stejného důvodu jako v modelu A1 přijmout nulovou hypotézu. Tedy, že model není statisticky významný.

Kointegrační vztah mezi bankovním a potravinářským průmyslem v modelu A3, jež byl statisticky ověřován F-testem, není statisticky významný z důvodu $F < F_{krit}$, kdy je nutné přijmout nulovou hypotézu.

Model B1 vyjadřuje kointegrační vztah mezi automobilovým a bankovním průmyslem, který není statisticky významný, neboť F-testem nebyla potvrzena jeho statistická významnost. Z tohoto důvodu jsou tyto dva sektory během krize na sobě nezávislé.

V modelu B2 dosáhla kritická hodnota hodnoty 3,859543, což je větší než vypočtená testovací statistika ve výši 2,653519. Z tohoto důvodu je nutné přijmout nulovou hypotézu a potvrdit, že model není statisticky významný.

Kointegrační vztah v modelu B3 nebyl statisticky potvrzen F-testem na hladině významnosti 5 % z důvodu $F < F_{\text{krit}}$, kdy je nutné přijmout nulovou hypotézu o tom, že model je statisticky nevýznamný.

Model C1 je sestaven na 1087 pozorování po krizi mezi automobilovým a bankovním sektorem. Ani v tomto případě nebylo možné přijmout alternativní hypotézu a označit model za statisticky významný.

Statisticky nevýznamný je také kointegrační vztah v modelu C2 mezi automobilovým a potravinářským průmyslem na hladině významnosti 5 %.

Model C3 popisující kointegrační vztah mezi bankovním a potravinářským průmyslem je také statisticky zamítnut na hladině významnosti 5 %, protože opět bylo nutné přijmout nulovou hypotézu, dle výsledných koeficientů testovací statistiky a vypočtené kritické hodnoty.

Na základě porovnání testovací a kritické statistiky všech modelů na hladině významnosti 5 % lze konstatovat, že všechny modely jsou statisticky nevýznamné. Ve všech případech platí, že $F < F_{\text{krit}}$, tudíž lze zamítnout alternativní hypotézu a přijmout nulovou hypotézu, z čehož vyplývá, že všechny modely jsou statisticky nevýznamné, což na druhou stranu potvrzuje zkoumanou myšlenku, že mezi indexy se nenachází žádný dlouhodobý rovnovážný stav.

4.8 Zhodnocení a zdůvodnění výsledku vzájemné komparace odvětvových indexů

Dlouhodobý vztah se neprojevil ani v jednom ze zkoumaných modelů, jak je uvedeno v tabulce 4.3 i přesto, že dané časové řady byly rozděleny na tři menší úseky z důvodu detailnější analýzy. Údaje v tabulce 4.3 byly získány pomocí softwaru EViews a na základě teoretické části této diplomové práce z kapitol 3.6, 3.7, a 3.8.

Tab. č. 4.3 – Přehled výsledných VEC modelů

Modely	Normalita	Autokorelace	Heteroskedasticita	Ekonomická významnost
A1	NE	ANO	ANO	NE
A2	NE	ANO	ANO	NE
A3	NE	ANO	ANO	NE
B1	NE	ANO	ANO	NE
B2	NE	ANO	ANO	NE
B3	NE	ANO	ANO	NE
C1	NE	ANO	ANO	NE
C2	NE	ANO	ANO	NE
C3	NE	ANO	ANO	NE

Zdroj: Vlastní zpracování

Při hledání dlouhodobého kointegračního vztahu mohlo dojít ke statistickým nebo ekonometrickým chybám. Z tohoto důvodu bylo v diplomové práci pokračováno sestavením příslušných VEC modelu přiřazení k jednotlivým modelům. Z odhadu VEC modelů byly sestaveny příslušné kointegrační rovnice, jež charakterizují jednotlivé vztahy v příslušných modelech. Pomocí výpočetního programu EViews byly zobrazeny jednotlivé kointegrační grafy. Grafickou analýzou nemohla být potvrzena stacionarita těchto grafů. Proto bylo nutné provést statistickou verifikaci modelů. Statistická verifikace modelu potvrdila, že ani jeden z modelů není statisticky významný. Tímto bylo potvrzeno, že v modelech neexistuje dlouhodobý rovnovážný stav. U většiny odhadů byl problém s normálním rozdělením reziduí, případně heteroskedasticitou nebo autokorelací. Přesto v praxi málokdy vycházejí všechny testy optimálně. Jednou z příčin může být malá statisticky vypovídací hodnota jednotlivých modelů. Z důvodu, že se jednotlivé sektory vzájemně neovlivňují, může být doporučeno investorům diverzifikovat své aktiva mezi jednotlivé sektory.

5 Závěr

Cílem diplomové práce bylo zjistit, zdali sektorové indexy mají mezi sebou dlouhodobý rovnovážný vztah, zda se nějak vzájemně ovlivňují. K tomuto účelu bylo využito testování kointegrace mezi jednotlivými sektory. Jako vzorek dat byly použity tři sektory, automobilový, finanční a potravinářský. Kointegrace mezi sektory byla posuzována pomocí vybraných sektorových indexů. Tyto tři indexy byly pro větší názornost a vypovídací schopnost rozděleny na tři období a to na období před finanční krizí, během finanční krize a po finanční krizi.

Práce byla rozdělena do pěti kapitol včetně úvodu a závěru. V druhé kapitole byla charakterizována podstata akciových indexů, jejich typů a způsobů výpočtů. Třetí kapitola byla zaměřena na charakteristiku a analýzu časových řad. Byly zde popsány jednotlivé testy stacionarity, kointegrace, vektorový model korekce chyb, autokorelace, heteroskedasticity a normality reziduí.

Čtvrtá kapitola diplomové práce obsahuje praktickou část diplomové práce. Pomocí kointegrace byl zkoumán vztah mezi vybranými sektorovými indexy ve třech rozdílných obdobích. Dále byla kapitola zaměřena na ověření výsledků pomocí statistické verifikace všech modelů.

Z výsledků kointegrační analýzy vyplývá, že neexistuje v žádném z testovaných sektorů vzájemný dlouhodobý kointegrační vztah, jež reprezentuje dlouhodobou rovnováhu mezi danými časovými řadami. Všechna tato tvrzení byla potvrzena statistickou verifikací pomocí koeficientů determinace a F-testu. Z tohoto důvodu může být doporučeno investorům jako další způsob možné diverzifikace nákup sektorových indexů, pokud to daný trh umožňuje. Dále je možno pro snížení rizika akciového trhu využít nákupu jednotlivých aktiv z různých sektorů, pokud nejsou k dispozici sektorové indexy. Tato diverzifikace může být další alternativou diverzifikace, než jen investice do souhrnného akciového indexu.

Jednou z dalších možných využití kointegrace v reálném světě investic může být použití kointegrace při statistických arbitrážích, kdy je třeba nalézt akciové páry, které jsou v dlouhodobé rovnováze a při výkyvu z této rovnováhy spekulovat o návratu aktiv k dlouhodobé rovnováze. Jak vyplývá z této práce, testování kointegrace mezi vybranými indexy lze použít nejen k lepším možnostem diverzifikace, ale i jako podklad pro další výzkum a studium v oblasti obchodování statistických arbitrází.

Seznam použité literatury

Odborné knihy

- [1] ARLT, Josef a Markéta ARLTOVÁ. *Ekonomické časové řady*. V Professional Publishing vyd. 1. Praha: Professional Publishing, 2009, 290 s. ISBN 978-80-86946-85-6.
- [2] BROOKS, Chris. *Introductory econometrics for finance*. 2nd ed. Cambridge: Cambridge University Press, 2008. 648 s. ISBN 978-052-1873-062.
- [3] CIPRA, Tomáš. *Finanční ekonometrie*. Praha: Ekopress, 2008. 538 s. ISBN 978-80-86929-43-9.
- [4] DAVIDSON, Russell a James G MACKINNON. *Econometric theory and methods*. New York: Oxford University Press, 2004, xviii, 750 p. ISBN 0195123727.
- [5] EHRMAN, Douglas S. *The handbook of pairs trading: strategies using equities, options, and futures*. Hoboken, N.J.: John Wiley & Sons, Inc., c2006, viii, 258 p. ISBN 0471727075.
- [6] HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. 214 s. ISBN 978-80-7431-088-1.
- [7] HUŠEK, Roman. *Ekonometrická analýza*. Vyd. 1. Praha: Oeconomica, 2007, 367 s. ISBN 978-80-245-1300-3.
- [8] CHAN, Ernest P. *Quantitative trading: how to build your own algorithmic trading business*. Hoboken, N.J.: John Wiley & Sons, c2009, xvii, 181 p. Wiley trading series. ISBN 0470284889.
- [9] CHAN, Ernest P. *Algorithmic trading: winning strategies and their rationale*. Hoboken, N.J.: John Wiley & Sons, Inc., 2013, xv, 207 p. Wiley trading series.
- [10] KULHÁNEK, Lumír a Stanislaw MATUSZEK. *Macroeconomic Factors and the Stock Market*. In LIS, S. a S. MIKLASZEWSKI, eds. *Transformacja, Integracja, Globalizacja*. Krakow: Akademia ekonomiczna, 2004, s. 467-488. ISBN 83-917312-7-8.
- [11] MILLS, Terence a Raphael MARKELLOS. *The econometric modelling of financial time series*. 3rd ed. New York: Cambridge University Press, 2008. 456 p. ISBN 05-217-1009-1.
- [12] MUSÍLEK, Petr. *Trhy cenných papírů*. 2., aktualiz. vyd. Praha: Ekopress, 2011. 520 s. ISBN 978-80-86929-70-5.

- [13] WHISTLER, Mark. *Trading pairs: capturing profits and hedging risk with statistical arbitrage strategies*. Hoboken, NJ: John Wiley & Sons, 2004, xiii, 279 p. ISBN 0471584282-.
- [14] ZMEŠKAL, Zdeněk, Dana DLUHOŠOVÁ a Tomáš TICHÝ. *Finanční modely: koncepty, metody, aplikace*. 3., přeprac. a rozš. vyd. Praha: Ekopress, 2013, viii, 267 s. ISBN 978-80-86929-91-0.
- [15] EVIEWS. *Heteroskedasticity and autocorrelation* [online]. 2014. vyd. 2015 [cit. 2015-03-24]. Dostupné z: http://www.eviews.com/Learning/timeseries_d.html
- [16] EVIEWS. *EViews Basics* [online]. 2014. vyd. 2015 [cit. 2015-03-24]. Dostupné z: <http://www.eviews.com/Learning/basics.html>
- [17] MATHWORKS. *Cointegration and Error Correction* [online]. 2015. vyd. 2015 [cit. 2015-03-24]. Dostupné z: <http://www.mathworks.com/help/econ/identify-cointegration.html#btdp660>
- [18] MATHWORKS. *Engle-Granger cointegration test* [online]. 2014 [cit. 2015-03-24]. Dostupné z: <http://www.mathworks.com/help/econ/egcitest.html>
- [19] MATHWORKS. *Johansen cointegration test* [online]. 2014. vyd. 2014 [cit. 2015-03-24]. Dostupné z: <http://www.mathworks.com/help/econ/jcitest.html>
- [20] MORÁVKA, Jan. TŘINECKÝ INŽENÝRING, a.s. KOINTEGRAČNÍ ANALÝZA NESTACIONÁRNÍCH VELIČIN [online]. Třinec, 2011 [cit. 2015-04-12]. Dostupné z: http://dsp.vscht.cz/konference_matlab/MATLAB06/prispevky/moravka/moravka.pdf
- [21] VECTOR AUTOREGRESSION AND VECTOR ERROR-CORRECTION [online]. 2011 [cit. 2015-04-12]. Dostupné z: <http://www.researchgate.net/publications/PublicPostFileLoader.html?id=54b866f0d3f3e8d018b45a1&key=a0d2c21c-8125-4e82-bc7c-5cc54c86618a>
- [22] STATISTICAL TABLES FOR ECONOMISTS. Tables of critical values [online]. 2001, č. 1 [cit. 2015-04-13]. Dostupné z: <http://www2.warwick.ac.uk/fac/soc/economics/staff/jsmith/manual/statisticaltables.pdf>

Seznam zkratek

ACF	autokorelační funkce, grafické znázornění - korelogram
ADF test	rozšířený Dickeyův – Fullerův test
EG metoda	Engleova-Grangerova metoda
H_0	nulová hypotéza
H_1	alternativní hypotéza
I	rád integrace
PP test	Phillipsův-Perronův test
VEC model	vektorový model s korekčním členem
ČR	časová řada
A1	model A1
A2	model A2
A3	model A3
B1	model B1
B2	model B2
B3	model B3
C1	model C1
C2	model C2
C3	model C3
NYSE	New York Stock Exchange
NASDAQ	National Association of Securities Dealers Automated Quotations
DAX	Deutscher Aktien-Index 30
DJIA	Dow Jones Industrial Average index

Prohlášení o využití výsledků diplomové práce

Prohlašuji, že

- Jsem byl seznámen s tím, že na mou diplomovou (bakalářskou) práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména §35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- beru na vědomí, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou (bakalářskou) práci užít (§35 odst. 3);
- souhlasím s tím, že diplomová (bakalářská) práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO a jeden výtisk bude uložen u vedoucího diplomové (bakalářské) práce. Souhlasím s tím, že bibliografické údaje o diplomové (bakalářské) práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou (bakalářskou) práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladu, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne 24. 4. 2015


Bc. Jan Šafářčík

Seznam příloh

Příloha č. 1: Testy autokorelace jednotlivých časových řad

Příloha č. 2: Testy autokorelace jednotlivých modelů

Příloha č. 3: Počet kointegračních vztahů v jednotlivých modelech

Příloha č. 4: Výsledky testů stacionarity a jednotkového kořene

Příloha č. 5: Výsledky testů stacionarity a jednotkového kořene po první diferenci

Příloha č. 6: Výsledky testů VEC modelů

Příloha č. 7: Výsledky Johansenových testů kointegrace

Příloha č. 8: Vstupní data, Evievs, CD-ROM

Příloha č. 1: Testy autokorelace jednotlivých časových řad

(1/1)

Grafy-Před krizí

Automobile

Date: 03/01/15 Time: 14:28
Sample: 1/03/2000 12/31/2007
Included observations: 2086

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.997	0.997	2074.9	0.000
		2 0.993	0.012	4137.0	0.000
		3 0.990	-0.006	6186.4	0.000
		4 0.987	0.035	8224.0	0.000
		5 0.984	-0.039	10249.0	0.000
		6 0.980	-0.040	12250.0	0.000
		7 0.977	0.054	14259.0	0.000
		8 0.974	-0.006	16245.0	0.000
		9 0.970	-0.016	18219.0	0.000
		10 0.967	0.004	20181.0	0.000

Banks

Date: 03/01/15 Time: 14:30
Sample: 1/03/2000 12/31/2007
Included observations: 2086

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.995	0.995	2069.0	0.000
		2 0.990	-0.007	4118.8	0.000
		3 0.986	0.006	6149.9	0.000
		4 0.981	0.016	8163.1	0.000
		5 0.976	0.003	10159.0	0.000
		6 0.972	0.017	12137.0	0.000
		7 0.968	0.028	14100.0	0.000
		8 0.964	0.023	16048.0	0.000
		9 0.960	0.002	17982.0	0.000
		10 0.957	0.015	19902.0	0.000

Food and Beverage

Date: 03/01/15 Time: 14:30
Sample: 1/03/2000 12/31/2007
Included observations: 2086

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.995	0.995	2070.1	0.000
		2 0.991	0.060	4124.5	0.000
		3 0.988	0.022	6164.5	0.000
		4 0.984	-0.006	8189.4	0.000
		5 0.980	0.041	10201.0	0.000
		6 0.977	-0.013	12199.0	0.000
		7 0.973	0.023	14184.0	0.000
		8 0.970	-0.003	16156.0	0.000
		9 0.967	0.016	18116.0	0.000
		10 0.963	-0.002	20063.0	0.000

Grafy-během krize

Graf 4 – automobile

Date: 03/01/15 Time: 14:32
Sample: 1/01/2008 12/31/2009
Included observations: 523

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.983	0.983	508.22	0.000
		2 0.966	0.005	1000.4	0.000
		3 0.950	0.008	1477.3	0.000
		4 0.937	0.084	1942.2	0.000
		5 0.923	-0.040	2394.1	0.000
		6 0.910	0.019	2833.8	0.000
		7 0.895	-0.040	3260.3	0.000
		8 0.883	0.048	3675.6	0.000
		9 0.871	0.024	4080.6	0.000
		10 0.859	-0.019	4475.3	0.000

Graf 5 - Banks Graf

Date: 03/01/15 Time: 14:33
Sample: 1/01/2008 12/31/2009
Included observations: 523

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.989	0.989	514.19	0.000
		2 0.977	-0.007	1017.6	0.000
		3 0.967	0.020	1511.0	0.000
		4 0.957	0.046	1995.6	0.000
		5 0.948	0.027	2472.1	0.000
		6 0.940	0.039	2941.5	0.000
		7 0.933	0.037	3404.7	0.000
		8 0.926	0.026	3862.3	0.000
		9 0.919	-0.033	4313.4	0.000
		10 0.911	-0.039	4757.2	0.000

6 - Food

Date: 03/01/15 Time: 14:33
Sample: 1/01/2008 12/31/2009
Included observations: 523

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.966	0.966	491.17	0.000
		2 0.939	0.075	955.59	0.000
		3 0.915	0.059	1398.1	0.000
		4 0.889	-0.050	1816.0	0.000
		5 0.864	0.005	2211.4	0.000
		6 0.834	-0.083	2581.0	0.000
		7 0.808	0.027	2928.3	0.000
		8 0.785	0.038	3257.0	0.000
		9 0.761	-0.019	3566.2	0.000
		10 0.740	0.044	3859.5	0.000

Grafy-Po krizi

Graf 7 - Autobile

Date: 03/01/15 Time: 14:35
Sample: 1/01/2010 3/27/2014
Included observations: 1092

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.996	0.996	1086.4	0.000
		2 0.992	0.006	2165.4	0.000
		3 0.988	0.015	3237.3	0.000
		4 0.985	-0.015	4301.9	0.000
		5 0.981	0.019	5359.5	0.000
		6 0.977	0.006	6410.4	0.000
		7 0.974	-0.001	7454.4	0.000
		8 0.970	-0.007	8491.5	0.000
		9 0.967	0.013	9522.1	0.000
		10 0.963	-0.040	10545.0	0.000

Graf 8 Banks

Date: 03/01/15 Time: 14:36
Sample: 1/01/2010 3/27/2014
Included observations: 1092

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.995	0.995	1084.8	0.000
		2 0.990	-0.060	2159.2	0.000
		3 0.985	-0.025	3222.7	0.000
		4 0.979	0.030	4276.0	0.000
		5 0.975	0.031	5319.8	0.000
		6 0.970	0.031	6354.9	0.000
		7 0.966	0.009	7381.8	0.000
		8 0.961	0.003	8400.5	0.000
		9 0.957	-0.026	9410.5	0.000
		10 0.952	0.011	10412.0	0.000

Graf 9 Food


Date: 03/01/15 Time: 14:36
Sample: 1/01/2010 3/27/2014
Included observations: 1092

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.996	0.996	1086.5	0.000
		2 0.992	0.011	2165.8	0.000
		3 0.989	-0.006	3237.9	0.000
		4 0.985	0.006	4302.8	0.000
		5 0.981	0.005	5360.7	0.000
		6 0.977	0.001	6411.6	0.000
		7 0.974	-0.002	7455.7	0.000
		8 0.970	0.007	8492.9	0.000
		9 0.966	-0.009	9523.3	0.000
		10 0.963	0.007	10547.0	0.000


Příloha č. 2: Testy autokorelace jednotlivých modelů

(2/1)


Model A1




Model A2




Model A3




Model B1




Model B2




Model B3




Model C1



Model C2



Model C3



Tab. 1 – Počet kointegračních vztahů v modelu A1

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 2 – Počet kointegračních vztahů v modelu A2

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	2	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 3 – Počet kointegračních vztahů v modelu A3

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 4 – Počet kointegračních vztahů v modelu B1

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 5 – Počet kointegračních vztahů v modelu B2

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	2	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 6 – Počet kointegračních vztahů v modelu B3

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 7 – Počet kointegračních vztahů v modelu C1

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 8 – Počet kointegračních vztahů v modelu C2

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 9 – Počet kointegračních vztahů v modelu C3

Data Trend:	None	None	Linear	Linear
Test Type	No Intercept	Intercept	Intercept	Intercept
	No Trend	No Trend	No Trend	Trend
Trace	0	0	0	0
Max-Eig	0	0	0	0

*Critical values based on MacKinnon-Haug-Michelis (1999)

Tab. 10 – Výsledky testů stacionarity a jednotkového kořene kritické hodnoty

ČR	Období	Test	S konstantou	S trendem a konstantou	Bez konstanty a trendu
Automobilový průmysl	Před krizí	ADF	-2,862724	-3,411964	-1,940976
		PP	-2,862724	-3,411964	-1,940976
	Během krize	ADF	-2,866857	-3,418453	-1,941431
		PP	-2,866857	-3,418453	-1,941431
	Po krizi	ADF	-2,863976	-3,413937	-1,941114
		PP	-2,863979	-3,413937	-1,941114
Bankovní průmysl	Před krizí	ADF	-2,862724	-3,411964	-1,940976
		PP	-2,862724	-3,411964	-1,940976
	Během krize	ADF	-2,866857	-3,418453	-1,941431
		PP	-2,866857	-3,418453	-1,941431
	Po krizi	ADF	-2,863981	-3,413941	-1,941114
		PP	-2,863979	-3,413937	-1,941114
Potravinařský průmysl	Před krizí	ADF	-2,862725	-3,411965	-1,940976
		PP	-2,862724	-3,411964	-1,940976
	Během krize	ADF	-2,866857	-3,418453	-1,941431
		PP	-2,866857	-3,418453	-1,941431
	Po krizi	ADF	-2,863979	-3,413937	-1,941114
		PP	-2,863979	-3,413937	-1,941114

Tab. 11 – Výsledky testů stacionarity a jednotkového kořene testovací statistiky

ČR	Období	Test	S konstantou	S trendem a konstantou	Bez konstanty a trendu
Automobilový průmysl	Před krizí	ADF	-2,002606	-1,932553	-0,838880
		PP	-2,007882	-1,949699	-0,836484
	Během krize	ADF	-2,437196	-1,983206	-0,806767
		PP	-2,426144	-1,983206	-0,815383
	Po krizi	ADF	-1,084039	-1,866996	-0,854060
		PP	-1,095655	-1,896942	0,845595
Bankovní průmysl	Před krizí	ADF	-1,987649	-1,908520	-0,471445
		PP	-1,853912	-1,762151	-0,468710
	Během krize	ADF	-2,152880	-1,873680	-1,32299
		PP	-2,114846	-1,740597	-1,407730
	Po krizi	ADF	-1,086366	-1,821015	0,844853
		PP	-1,059178	-1,756157	0,918963
Potravinářský průmysl	Před krizí	ADF	-2,056200	-2,321085	-0,035328
		PP	-1,975534	-2,200655	-0,066840
	Během krize	ADF	-3,089447	-2,814893	-0,418878
		PP	-2,914940	-2,570194	-0,436952
	Po krizi	ADF	-1,115052	-2,903344	1,536825
		PP	-1,121562	-2,936059	1,523516

Příloha č. 5: Výsledky testů stacionarity a jednotkového kořene po první diferenci (5/1)

Tab. 12 – Výsledky testů stacionarity a jednotkového kořene kritické hodnoty

ČR	Období	Test	S konstantou	S trendem a konstantou	Bez konstanty a trendu
Automobilový průmysl	Před krizí	ADF	-2,862725	-3,411965	-1,940976
		PP	-2,862725	-3,411965	-1,940976
	Během krize	ADF	-2,866868	-3,418469	-1,941432
		PP	-2,866868	-3,418469	-1,941432
	Po krizi	ADF	-2,863981	-3,413941	-1,941114
		PP	-2,863981	-3,413941	-1,941114
Bankovní průmysl	Před krizí	ADF	-2,862725	-3,411965	-1,940976
		PP	-2,862725	-3,411965	-1,940976
	Během krize	ADF	-2,866868	-3,411846	-1,941432
		PP	-2,866868	-3,418469	-1,941432
	Po krizi	ADF	-2,863981	-3,413941	-1,941114
		PP	-2,863981	-3,413941	-1,941114
Potravinařský průmysl	Před krizí	ADF	-2,862725	-3,411965	-1,940976
		PP	-2,862725	-3,411965	-1,940976
	Během krize	ADF	-2,866879	-3,418486	-1,941433
		PP	-2,866868	-3,418469	-1,941432
	Po krizi	ADF	-2,863981	-3,413941	-1,941114
		PP	-2,863981	-3,413941	-1,941114

Tab. 13 – Výsledky testů stacionarity a jednotkového kořene testovací statistika

ČR	Období	Test	S konstantou	S trendem a konstantou	Bez konstanty a trendu
Automobilový průmysl	Před krizí	ADF	-45,44144	-45,43445	-45,44837
		PP	-45,44237	-45,43541	-45,44929
	Během krize	ADF	-23,39838	-23,48343	-23,41099
		PP	-23,39858	-23,49274	-23,41099
	Po krizi	ADF	-32,46022	-32,44600	-32,44423
		PP	-32,45643	-32,44207	-32,44072
Bankovní průmysl	Před krizí	ADF	-45,84071	-45,84020	-45,85120
		PP	-46,00018	-46,01547	-46,01109
	Během krize	ADF	-22,01303	-22,04002	-22,00639
		PP	-22,14962	-22,21826	-22,09729
	Po krizi	ADF	-29,69609	-29,68654	-29,67971
		PP	-29,63436	-29,62319	-29,62637
Potravinářský průmysl	Před krizí	ADF	-48,86513	-48,85373	-48,87608
		PP	-49,07758	-49,06558	-49,08865
	Během krize	ADF	-18,63482	-18,71732	-18,65007
		PP	-25,41668	-25,44964	-25,43965
	Po krizi	ADF	-33,39821	-33,38406	-33,32520
		PP	-33,39664	-33,38273	-33,32403

Tab. 6.1 - Odhad VEC modelu A1

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:41

Sample (adjusted): 1/06/2000 12/31/2007

Included observations: 2083 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_BANKS(-1)	1.000000	
CLOSE_AUTOMOBILE(-1)	-0.376461 (0.08556) [-4.39983]	
C	-53.88589	
Error Correction:	D(CLOSE_BANKS)	D(CLOSE_AUTOMOBILE)
CointEq1	-0.004822 (0.00312) [-1.54467]	0.008066 (0.00654) [1.23401]
D(CLOSE_BANKS(-1))	0.041610 (0.02639) [1.57661]	0.354081 (0.05526) [6.40731]
D(CLOSE_BANKS(-2))	-0.010234 (0.02656) [-0.38536]	0.079043 (0.05561) [1.42140]
D(CLOSE_AUTOMOBILE(-1))	-0.036074 (0.01259) [-2.86525]	-0.092953 (0.02636) [-3.52599]
D(CLOSE_AUTOMOBILE(-2))	0.015062 (0.01247) [1.20744]	0.004658 (0.02612) [0.17834]
C	-0.006545 (0.04111) [-0.15921]	-0.035771 (0.08607) [-0.41559]
R-squared	0.005862	0.021451
Adj. R-squared	0.003469	0.019096
Sum sq. resids	7309.014	32045.36
S.E. equation	1.875906	3.927935
F-statistic	2.449549	9.106244
Log likelihood	-4263.043	-5802.426
Akaike AIC	4.098937	5.576981
Schwarz SC	4.115188	5.593231
Mean dependent	-0.005982	-0.035655
S.D. dependent	1.879169	3.965984

Zdroj: Program EViews

Tab. č. 6.2 - Odhad VEC modelu A2

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:45

Sample (adjusted): 1/06/2000 12/31/2007

Included observations: 2083 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_AUTOMOBILE(-1)	1.000000	
CLOSE_FOOD(-1)	-2.299917 (0.58300) [-3.94497]	
C	197.0899	
Error Correction:	D(CLOSE_AUTOMOBILE)	D(CLOSE_FOOD)
CointEq1	0.001098 (0.00180) [0.60968]	0.003489 (0.00100) [3.49172]
D(CLOSE_AUTOMOBILE(-1))	-0.024284 (0.02341) [-1.03740]	-0.050466 (0.01299) [-3.88628]
D(CLOSE_AUTOMOBILE(-2))	0.035400 (0.02333) [1.51750]	0.028783 (0.01294) [2.22414]
D(CLOSE_FOOD(-1))	0.160536 (0.04197) [3.82545]	-0.033506 (0.02328) [-1.43925]
D(CLOSE_FOOD(-2))	-0.059311 (0.04185) [-1.41709]	-0.033975 (0.02322) [-1.46327]
C	-0.036107 (0.08663) [-0.41678]	0.008368 (0.04806) [0.17410]
R-squared	0.008771	0.020113
Adj. R-squared	0.006384	0.017754
Sum sq. resids	32460.63	9989.839
S.E. equation	3.953304	2.193113
F-statistic	3.675525	8.526303
Log likelihood	-5815.836	-4588.470
Akaike AIC	5.589857	4.411397
Schwarz SC	5.606107	4.427648
Mean dependent	-0.035655	0.008560
S.D. dependent	3.965984	2.212844

Tab. č. 6.3 - Odhad VEC modelu A3

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:48

Sample (adjusted): 1/06/2000 12/31/2007

Included observations: 2083 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_BANKS(-1)	1.000000	
CLOSE_FOOD(-1)	1.880630 (0.99536) [1.88940]	
C	-560.8514	
Error Correction:	D(CLOSE_BANKS)	D(CLOSE_FOOD)
CointEq1	-0.001764 (0.00073) [-2.41987]	-0.001405 (0.00085) [-1.65442]
D(CLOSE_BANKS(-1))	0.007307 (0.02710) [0.26958]	-0.175503 (0.03157) [-5.55904]
D(CLOSE_BANKS(-2))	0.005392 (0.02724) [0.19794]	0.107910 (0.03173) [3.40068]
D(CLOSE_FOOD(-1))	-0.014781 (0.02325) [-0.63576]	0.028846 (0.02708) [1.06515]
D(CLOSE_FOOD(-2))	-0.014615 (0.02294) [-0.63698]	-0.072982 (0.02673) [-2.73072]
C	-0.005632 (0.04116) [-0.13685]	0.008549 (0.04794) [0.17832]
R-squared	0.003400	0.024868
Adj. R-squared	0.001001	0.022521
Sum sq. resids	7327.118	9941.357
S.E. equation	1.878228	2.187785
F-statistic	1.417135	10.59371
Log likelihood	-4265.620	-4583.403
Akaike AIC	4.101411	4.406532
Schwarz SC	4.117661	4.422783
Mean dependent	-0.005982	0.008560
S.D. dependent	1.879169	2.212844

Tab. č. 6.4 - Odhad VEC modelu B1

(6/4)

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:56

Sample (adjusted): 1/04/2008 12/31/2009

Included observations: 520 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_AUTOMOBILE(-1)	1.000000	
CLOSE_BANKS(-1)	-1.345059 (0.30651) [-4.38829]	
C	-77.14065	
Error Correction:	D(CLOSE_AUTOMOBILE)	D(CLOSE_BANKS)
CointEq1	-0.011716 (0.01147) [-1.02120]	0.011824 (0.00669) [1.76654]
D(CLOSE_AUTOMOBILE(-1))	-0.164304 (0.04819) [-3.40941]	-0.041745 (0.02811) [-1.48486]
D(CLOSE_AUTOMOBILE(-2))	-0.035324 (0.04624) [-0.76398]	-0.019461 (0.02697) [-0.72147]
D(CLOSE_BANKS(-1))	0.586209 (0.08187) [7.15993]	0.064698 (0.04776) [1.35457]
D(CLOSE_BANKS(-2))	0.112652 (0.08560) [1.31605]	-0.001371 (0.04994) [-0.02745]
C	-0.044778 (0.18981) [-0.23591]	-0.089516 (0.11073) [-0.80842]
R-squared	0.097614	0.011296
Adj. R-squared	0.088836	0.001679
Sum sq. resids	9602.941	3268.119
S.E. equation	4.322356	2.521549
F-statistic	1.12026	1.174540
Log likelihood	-1496.007	-1215.765
Akaike AIC	5.776950	4.699095
Schwarz SC	5.826032	4.748178
Mean dependent	-0.091827	-0.089942
S.D. dependent	4.528166	2.523668

Tab. č. 6.5 - Odhad VEC modelu B2

(6/5)

Vector Error Correction Estimates

Date: 02/24/15 Time: 19:01

Sample (adjusted): 1/04/2008 12/31/2009

Included observations: 520 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_AUTOMOBILE(-1)	1.000000	
CLOSE_FOOD(-1)	-5.411873 (1.13723) [-4.75880]	
C	816.9907	
Error Correction:	D(CLOSE_AUTOMOBILE)	D(CLOSE_FOOD)
CointEq1	0.007149 (0.00460) [1.55402]	0.008703 (0.00265) [3.28760]
D(CLOSE_AUTOMOBILE(-1))	-0.136775 (0.04582) [-2.98474]	-0.033572 (0.02637) [-1.27311]
D(CLOSE_AUTOMOBILE(-2))	-0.037513 (0.04393) [-0.85400]	0.002186 (0.02528) [0.08650]
D(CLOSE_FOOD(-1))	0.535259 (0.07997) [6.69306]	-0.073317 (0.04602) [-1.59315]
D(CLOSE_FOOD(-2))	0.228127 (0.08201) [2.78183]	-0.069704 (0.04719) [-1.47706]
C	-0.092726 (0.19085) [-0.48585]	-0.028996 (0.10983) [-0.26402]
R-squared	0.085845	0.042138
Adj. R-squared	0.076952	0.032821
Sum sq. resids	9728.193	3221.462
S.E. equation	4.350453	2.503485
F-statistic	2.653519	4.522390
Log likelihood	-1499.376	-1212.026
Akaike AIC	5.789909	4.684716
Schwarz SC	5.838991	4.733798
Mean dependent	-0.091827	-0.023308
S.D. dependent	4.528166	2.545608

Tab. č. 6.6 - Odhad VEC modelu B3

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:58

Sample (adjusted): 1/04/2008 12/31/2009

Included observations: 520 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_FOOD(-1)	1.000000	
CLOSE_BANKS(-1)	-0.317438 (0.09368) [-3.38847]	
C	-158.7294	
Error Correction:	D(CLOSE_FOOD D)	D(CLOSE_BANKS KS)
CointEq1	-0.055060 (0.01638) [-3.36140]	-0.028758 (0.01654) [-1.73919]
D(CLOSE_FOOD(-1))	0.005397 (0.05435) [0.09929]	0.112269 (0.05487) [2.04614]
D(CLOSE_FOOD(-2))	-0.049705 (0.05300) [-0.93777]	-0.070946 (0.05350) [-1.32598]
D(CLOSE_BANKS(-1))	-0.164079 (0.05361) [-3.06033]	-0.021658 (0.05412) [-0.40018]
D(CLOSE_BANKS(-2))	-0.012711 (0.05322) [-0.23886]	0.025926 (0.05372) [0.48263]
C	-0.040685 (0.10923) [-0.37246]	-0.089267 (0.11027) [-0.80955]
R-squared	0.054702	0.019912
Adj. R-squared	0.045506	0.010378
Sum sq. resids	3179.210	3239.640
S.E. equation	2.487013	2.510538
F-statistic	2.948734	2.088549
Log likelihood	-1208.593	-1213.489
Akaike AIC	4.671513	4.690343
Schwarz SC	4.720596	4.739425
Mean dependent	-0.023308	-0.089942
S.D. dependent	2.545608	2.523668

Tab. č. 6.7 - Odhad VEC modelu C1

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:15

Sample (adjusted): 1/06/2010 3/27/2014

Included observations: 1089 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_AUTOMOBILE(-1)	1.000000	
CLOSE_BANKS(-1)	-3.642367 (0.65449) [-5.56522]	
C	98.41813	
Error Correction:	D(CLOSE_AUTOMOBILE)	D(CLOSE_BANKS)
CointEq1	-0.007332 (0.00488) [-1.50295]	0.001072 (0.00149) [0.71750]
D(CLOSE_AUTOMOBILE(-1))	-0.167114 (0.03551) [-4.70568]	-0.024478 (0.01088) [-2.24986]
D(CLOSE_AUTOMOBILE(-2))	-0.071226 (0.03480) [-2.04698]	0.002459 (0.01066) [0.23065]
D(CLOSE_BANKS(-1))	1.006971 (0.11653) [8.64141]	0.143302 (0.03570) [4.01412]
D(CLOSE_BANKS(-2))	0.364022 (0.12036) [3.02441]	0.059506 (0.03687) [1.61378]
C	0.081838 (0.09937) [0.82357]	0.028020 (0.03044) [0.92043]
R-squared	0.076453	0.018298
Adj. R-squared	0.072189	0.013766
Sum sq. resids	11616.60	1090.279
S.E. equation	3.275105	1.003355
F-statistic	1.93057	4.037228
Log likelihood	-2834.151	-1545.863
Akaike AIC	5.216072	2.850070
Schwarz SC	5.243581	2.877579
Mean dependent	0.104316	0.032727
S.D. dependent	3.400130	1.010333

Tab. č. 6.8 - Odhad VEC modelu C2

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:21

Sample (adjusted): 1/06/2010 3/27/2014

Included observations: 1089 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_AUTOMOBILE(-1)	1.000000	
CLOSE_FOOD(-1)	-1.417171 (0.42206) [-3.35775]	
C	87.49536	
Error Correction:	D(CLOSE_AUTO MOBILE)	D(CLOSE_FOOD)
CointEq1	-0.007088 (0.00353) [-2.00598]	-0.001231 (0.00200) [-0.61635]
D(CLOSE_AUTOMOBILE(-1))	-0.076280 (0.03403) [-2.24174]	-0.032395 (0.01923) [-1.68427]
D(CLOSE_AUTOMOBILE(-2))	-0.021181 (0.03343) [-0.63357]	0.013100 (0.01890) [0.69323]
D(CLOSE_FOOD(-1))	0.345543 (0.06035) [5.72601]	0.013606 (0.03411) [0.39887]
D(CLOSE_FOOD(-2))	0.073230 (0.06110) [1.19843]	0.034482 (0.03454) [0.99836]
C	0.074263 (0.10169) [0.73028]	0.092678 (0.05748) [1.61236]
R-squared	0.035545	0.005029
Adj. R-squared	0.031092	0.000435
Sum sq. resids	12131.15	3875.893
S.E. equation	3.346854	1.891785
F-statistic	2.982735	1.094802
Log likelihood	-2857.751	-2236.476
Akaike AIC	5.259413	4.118413
Schwarz SC	5.286923	4.145922
Mean dependent	0.104316	0.095317
S.D. dependent	3.400130	1.892197

Tab. č. 6.9 - Odhad VEC modelu C3

Vector Error Correction Estimates

Date: 02/24/15 Time: 18:22

Sample (adjusted): 1/06/2010 3/27/2014

Included observations: 1089 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
CLOSE_BANKS(-1)	1.000000	
CLOSE_FOOD(-1)	-0.376865 (0.13568) [-2.77759]	
C	-6.168481	
Error Correction:	D(CLOSE_BANKS)	D(CLOSE_FOOD)
CointEq1	-0.006403 (0.00355) [-1.80547]	-0.004834 (0.00669) [-0.72293]
D(CLOSE_BANKS(-1))	0.103102 (0.03948) [2.61119]	0.041260 (0.07444) [0.55429]
D(CLOSE_BANKS(-2))	0.055295 (0.03932) [1.40612]	0.072734 (0.07413) [0.98110]
D(CLOSE_FOOD(-1))	-0.002958 (0.02099) [-0.14091]	-0.027646 (0.03958) [-0.69856]
D(CLOSE_FOOD(-2))	-0.004783 (0.02093) [-0.22852]	0.009141 (0.03946) [0.23164]
C	0.028020 (0.03052) [0.91817]	0.093134 (0.05753) [1.61884]
R-squared	0.016155	0.003111
Adj. R-squared	0.011613	-0.001492
Sum sq. resids	1092.659	3883.366
S.E. equation	1.004449	1.893607
F-statistic	3.556626	0.675894
Log likelihood	-1547.050	-2237.524
Akaike AIC	2.852250	4.120339
Schwarz SC	2.879760	4.147848
Mean dependent	0.032727	0.095317
S.D. dependent	1.010333	1.892197

Tab. č. 7.1 – Johansenův test kointegrace A1

Date: 03/09/15 Time: 13:29
 Sample (adjusted): 1/10/2000 12/31/2007
 Included observations: 2081 after adjustments
 Trend assumption: Linear deterministic trend
 Series: CLOSE_AUTOMOBILE_PARTS CLOSE_BANKS
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.003550	10.79762	15.49471	0.2242
At most 1	0.001631	3.396668	3.841466	0.0653

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.003550	7.400956	14.26460	0.4429
At most 1	0.001631	3.396668	3.841466	0.0653

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.2 – Johansenův test kointegrace A2

Date: 03/09/15 Time: 13:30
Sample (adjusted): 1/10/2000 12/31/2007
Included observations: 2081 after adjustments
Trend assumption: Linear deterministic trend
Series: CLOSE_AUTOMOBILE_PARTS
CLOSE_FOOD__BEVERAGE
Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.005251	14.75060	15.49471	0.0225
At most 1 *	0.003260	6.794895	3.841466	0.0091

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.005251	10.95571	14.26460	0.1564
At most 1 *	0.003260	6.794895	3.841466	0.0091

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.3 – Johansenův test kointegrace A3

Date: 03/09/15 Time: 13:29

Sample (adjusted): 1/10/2000 12/31/2007

Included observations: 2081 after adjustments

Trend assumption: Linear deterministic trend

Series: CLOSE_BANKS CLOSE_FOOD___BEVERAGE

Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.002950	11.38558	15.49471	0.1889
At most 1 *	0.002514	5.237530	3.841466	0.0221

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.002950	6.148048	14.26460	0.5943
At most 1 *	0.002514	5.237530	3.841466	0.0221

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Během krize

Tab. č. 7.4 – Johansenův test kointegrace B1

Date: 03/09/15 Time: 13:18

Sample (adjusted): 1/08/2008 12/31/2009

Included observations: 518 after adjustments

Trend assumption: Linear deterministic trend (restricted)

Series: CLOSE_AUTOMOBILE CLOSE_BANKS

Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.018245	14.68827	25.87211	0.6005
At most 1	0.009893	5.150147	12.51798	0.5749

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.018245	9.538120	19.38704	0.6681
At most 1	0.009893	5.150147	12.51798	0.5749

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.5 – Johansenův test kointegrace B2

Date: 03/09/15 Time: 13:27
 Sample (adjusted): 1/08/2008 12/31/2009
 Included observations: 518 after adjustments
 Trend assumption: Linear deterministic trend
 Series: CLOSE_AUTOMOBILE CLOSE_FOOD
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.022684	14.34066	15.49471	0.0372
At most 1 *	0.008564	4.455162	3.841466	0.0348

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.022684	11.88549	14.26460	0.1150
At most 1 *	0.008564	4.455162	3.841466	0.0348

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.6 – Johansenův test kointegrace B3

Date: 03/09/15 Time: 13:26
 Sample (adjusted): 1/08/2008 12/31/2009
 Included observations: 518 after adjustments
 Trend assumption: Linear deterministic trend
 Series: CLOSE_BANKS CLOSE_FOOD
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.020951	13.83146	15.49471	0.0877
At most 1	0.005513	2.863611	3.841466	0.0906

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.020951	10.96785	14.26460	0.1558
At most 1	0.005513	2.863611	3.841466	0.0906

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.7 – Johansenův test kointegrace C1

Date: 03/09/15 Time: 13:32
 Sample (adjusted): 1/08/2010 3/27/2014
 Included observations: 1087 after adjustments
 Trend assumption: Linear deterministic trend
 Series: CLOSE_AUTOMOBILE_PARTS CLOSE_BANKS
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.004648	5.847086	15.49471	0.7135
At most 1	0.000720	0.782463	3.841466	0.3764

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.004648	5.064623	14.26460	0.7336
At most 1	0.000720	0.782463	3.841466	0.3764

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.8 – Johansenův test kointegrace C2

Date: 03/09/15 Time: 13:32
 Sample (adjusted): 1/08/2010 3/27/2014
 Included observations: 1087 after adjustments
 Trend assumption: Linear deterministic trend
 Series: CLOSE_AUTOMOBILE_PARTS
 CLOSE_FOOD__BEVERAGE
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.003514	5.566480	15.49471	0.7461
At most 1	0.001600	1.740234	3.841466	0.1871

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.003514	3.826246	14.26460	0.8772
At most 1	0.001600	1.740234	3.841466	0.1871

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Tab. č. 7.9 – Johansenův test kointegrace C3

Date: 03/09/15 Time: 13:32

Sample (adjusted): 1/08/2010 3/27/2014

Included observations: 1087 after adjustments

Trend assumption: Linear deterministic trend

Series: CLOSE_BANKS CLOSE_FOOD___BEVERAGE

Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None	0.003464	5.674753	15.49471	0.7336
At most 1	0.001749	1.902626	3.841466	0.1678

Trace test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None	0.003464	3.772127	14.26460	0.8826
At most 1	0.001749	1.902626	3.841466	0.1678

Max-eigenvalue test indicates no cointegration at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values